

**UNIVERSIDADE FEDERAL DA PARAÍBA**  
**CENTRO DE INFORMÁTICA**  
**DEPARTAMENTO DE COMPUTAÇÃO CIENTÍFICA**  
**BACHARELADO EM MATEMÁTICA COMPUTACIONAL**

**EDVALDO FRANCISCO DE MELO NETO**

**CLASSIFICAÇÃO DE REGIÕES FAVORÁVEIS A CONCENTRAÇÃO  
DE HIDROCARBONETOS EM IMAGENS SÍSMICAS UTILIZANDO  
REDES NEURAIIS ARTIFICIAIS**

João Pessoa

2018

EDVALDO FRANCISCO DE MELO NETO

**CLASSIFICAÇÃO DE REGIÕES FAVORÁVEIS A CONCENTRAÇÃO  
DE HIDROCARBONETOS EM IMAGENS SÍSMICAS UTILIZANDO  
REDES NEURAS ARTIFICIAIS**

Trabalho de Conclusão de Curso apresentado  
ao Departamento de Computação Científica na  
Universidade Federal da Paraíba, como parte  
dos requisitos para a obtenção do título de  
Bacharel em Matemática Computacional.

Orientador: Prof. Dr. Moisés Dantas dos Santos

João Pessoa

2018

**Catálogo na publicação**  
**Seção de Catalogação e Classificação**

N469c Neto, Edvaldo Francisco de Melo.

Classificação de Regiões Favoráveis a Concentração de Hidrocarbonetos em Imagens Sísmicas Utilizando Redes Neurais Artificiais / Edvaldo Francisco de Melo Neto. - João Pessoa, 2018.

63 f.

Orientação: Moisés Dantas do Santos.

Monografia (Graduação) - UFPB/Informática.

1. imagens sísmicas. 2. redes neurais artificiais. 3. descritores de Haralick. 4. funções geoestatísticas. 5. reconhecimento de padrões. I. do Santos, Moisés Dantas. II. Título.

UFPB/BC

## **AGRADECIMENTOS**

A Deus por ter me dado forças e guiado os meus caminhos para chegar até aqui.

A toda a minha família e amigos, em especial aos meus pais, Sandra Francisco de Melo Araújo e Ricardo Luiz Marinho de Araújo por todo o apoio incondicional em toda a minha vida. Também a minha avó, Maria Alves de Melo, e meu tio, Evandro Francisco de Melo por estarem sempre ao meu lado.

Ao meu professor e orientador, Moisés Dantas dos Santos, pelos ensinamentos, incentivo, amizade e por acreditar em mim durante todo esse tempo. Muito obrigado! Também aos professores José Fabrício Lima de Souza e Rafael Magalhães por todo apoio, amizade e pelas valiosas contribuições ao longo deste trabalho.

A todos os professores e amigos do LAMEP (Laboratório de Modelagem em Engenharia de Petróleo), sempre dispostos a ajudar.

Aos professores do curso de Bacharelado em Matemática Computacional, pelo aprendizado adquirido durante todo esse tempo.

Muito obrigado a todos pela contribuição e apoio ao longo dessa jornada.

## RESUMO

Identificar regiões favoráveis a concentração de hidrocarbonetos (regiões de interesse) em dados sísmicos é uma tarefa importante, realizada subjetivamente por geólogos e geofísicos, a qual demanda bastante tempo e experiência. Neste trabalho foi desenvolvido um processo automático para detectar as regiões de interesse em imagens sísmicas utilizando os descritores de Haralick e as funções geoestatísticas. Esse método se baseia no uso de redes neurais artificiais para reconhecimento de padrões em conjunto com esses descritores. Para avaliar o desempenho da rede, foram utilizadas as métricas estatísticas de acurácia, sensibilidade, especificidade, precisão e  $F_1$  score. A rede obteve um desempenho de até 98,3% de acurácia e  $F_1$  score, 96,7% de sensibilidade e 100% de especificidade e precisão.

**Palavras-chave:** Imagens sísmicas, redes neurais artificiais, descritores de Haralick, funções geoestatísticas, reconhecimento de padrões.

## ABSTRACT

Identifying regions favorable to the concentration of hydrocarbons (regions of interest) in seismic data is an important task, performed subjectively by geologists and geophysicists, which requires considerable time and experience. In this work an automatic process was developed to detect the regions of interest in seismic images using the Haralick descriptors and the geostatistical functions. This method is based on the use of artificial neural networks for the pattern recognition in conjunction with these descriptors. To evaluate the performance of the network, statistical metrics were used for accuracy, sensitivity, specificity, precision and  $F_1$ score. The network achieved a performance of up to 98,3% accuracy and  $F_1$ score, 96,7% sensitivity and 100% specificity and precision.

**Key words:** Seismic images, artificial neural networks, Haralick descriptors, geostatistical functions, pattern recognition.

## SUMÁRIO

<b>1. INTRODUÇÃO .....</b>	<b>11</b>
<b>2. FUNDAMENTAÇÃO TEÓRICA .....</b>	<b>13</b>
2.1 Método Sísmico .....	13
2.1.1 Ondas Sísmicas .....	13
2.1.2 Método Sísmico de Reflexão .....	14
2.2 Processamento Digital de Imagens .....	17
2.2.1 Amostragem e Quantização de Imagens .....	18
2.3 Textura .....	19
2.3.1 Descritores de Haralick .....	19
2.3.2 Descritores Geoestatísticos .....	23
2.4 Redes Neurais Artificiais .....	24
2.4.1 Neurônio Biológico .....	25
2.4.2 Neurônio Artificial .....	25
2.4.3 Arquiteturas de Redes Neurais .....	27
2.4.4 Aprendizado .....	28
2.5 Reconhecimento de Padrões .....	29
2.5.1 Etapas do Reconhecimento de Padrões .....	29
<b>3. METODOLOGIA .....</b>	<b>34</b>
3.1 Aquisição de Imagens .....	34
3.1.1 Geração de Subimagens .....	35
3.2 Normalização dos Dados .....	38
3.3 Dados de Entrada e Saída .....	39
3.4 Arquitetura da Rede Neural .....	41
<b>4. RESULTADOS .....</b>	<b>43</b>
4.1 Escolha dos Parâmetros .....	43
4.2 Identificação das Regiões de Interesse .....	54
4.2.1 Caso 1: Identificação da Rede Utilizando Todas as Imagens .....	54
4.2.2 Caso 2: Teste às Cegas .....	57
<b>5. CONSIDERAÇÕES FINAIS .....</b>	<b>60</b>
<b>6. REFERÊNCIAS BIBLIOGRÁFICAS .....</b>	<b>61</b>

## LISTA DE FIGURAS

Figura 1: Imagem sísmica da Bacia Sergipe-Alagoas. (a) Imagem Sísmica SEAL-M-567-NW, (b) classificação da imagem sísmica feita por um especialista, onde a região de interesse está destacada de amarelo. Fonte: ANP. ....	12
Figura 2: Etapas da exploração sísmica. ....	14
Figura 3: Processo de aquisição sísmica. Adaptado de Silva (2004) citado por Motta (2015). ....	15
Figura 4: Amostras de dados sísmicos. Traço sísmico (esquerda), linha sísmica (centro) e volume sísmico (direita). Adaptado de Silva (2004) citado por Motta (2015). ....	16
Figura 5: Modelos geológicos. Adaptado de Robinson e Treitel (1980) citado por Barros (2012). ....	16
Figura 6: Iluminação ( $I$ ) e refletância ( $R$ ) de uma imagem. Adaptado de Marques Filho e Vieira Neto (1999). ....	18
Figura 7: Imagem Digital. (a) Imagem em níveis de cinza $4 \times 4$ , (b) digitalização da imagem. ....	19
Figura 8: Ângulos normalmente utilizados para obtenção da matriz de coocorrência. ....	20
Figura 9: Obtenção da matriz de coocorrência $P(i, j, 1, 0^\circ)$ de uma imagem com 4 níveis de cinza. Representação matricial da imagem (esquerda), resultado da matriz de coocorrência (direita). ....	20
Figura 10: Representação do vetor $h$ . (a) Ilustração da separação de dois pixels pelo vetor $h$ , (b) todos os $N$ pares do vetor $h$ . ....	23
Figura 11: Neurônio Biológico. Adaptado de Silva et al. (2010). ....	25
Figura 12: Neurônio Artificial. ....	26
Figura 13: Funções de ativação. (a) Degrau, (b) sigmoidal, (c) linear, (d) tangente hiperbólica. ....	27
Figura 14: Arquiteturas de redes neurais. (a) Arquitetura de camada única, (b) arquitetura de camadas múltiplas. Adaptado de Silva et al. (2010). ....	28
Figura 15: Classificação de um objeto desconhecido a uma determinada classe. ....	29
Figura 16: Etapas de um sistema de reconhecimento de padrões. ....	30
Figura 17: Exemplo de uma curva ROC. ....	33
Figura 18: Imagem Sísmica SEAL-M-567-NW com dimensão $575 \times 855$ . Fonte: ANP. ....	34
Figura 19: Geração das subimagens. ....	35



Figura 20: Obtenção das regiões de interesse. (a) Imagem com regiões já classificadas, (b) extração da região de interesse. ....	36
Figura 21: Obtenção das subimagens contidas na região de interesse. ....	37
Figura 22: Exemplo de subimagem que não possui mais de 10 pixels com cor branca. ....	37
Figura 23: Transformação dos dados. Descritores com valores originais (esquerda), normalização dos descritores (direita). ....	39
Figura 24: Transformação de uma subimagem em um vetor. ....	40
Figura 25: Arquitetura da rede em dimensões diferentes. (a) Dimensão $10 \times 10$ , (b) dimensão $15 \times 15$ , (c) dimensão $20 \times 20$ . ....	41
Figura 26: Avaliação do desempenho da rede (Caso 1). (a) Resultados para a matriz de confusão em cada taxa de treinamento, (b) Resultados da curva ROC para cada taxa de treinamento. ....	55
Figura 27: Comparação entre os resultados no Caso 1. (a) Resultado esperado, (b) resultado obtido pela rede neural. ....	56
Figura 28: Avaliação do desempenho da rede (Caso 2). (a) Resultado para a matriz de confusão para cada taxa de treinamento, (b) Resultado da curva ROC em cada taxa de treinamento. ....	57
Figura 29: Comparação entre os resultados no Caso 2 (imagem SEAL-M-567-NW). (a) Resultado esperado, (b) Resultado obtido pela rede neural. ....	58
Figura 30: Comparação entre os resultados no Caso 2 (imagem SEAL-M-567-SW). (a) Resultado esperado, (b) resultado obtido pela rede neural. ....	59

## LISTA DE TABELAS

Tabela 1: Matriz de confusão. ....	31
Tabela 2: Total de subimagens contidas nas regiões de interesse e não contidas. ....	38
Tabela 3: Parâmetros que serão escolhidos para a rede neural.....	43
Tabela 4: Resultados da rede para subimagens $10 \times 10$ com 60% para treino, 20% para validação e 20% para teste.....	44
Tabela 5: Resultados da rede para subimagens $10 \times 10$ com 70% para treino, 15% para validação e 15% para teste.....	44
Tabela 6: Resultados da rede para subimagens $10 \times 10$ com 80% para treino, 10% para validação e 10% para teste.....	45
Tabela 7: Resultados da rede para subimagens $10 \times 10$ com 90% para treino, 5% para validação e 5% para teste.....	46
Tabela 8: Resultados da rede para subimagens $15 \times 15$ com 60% para treino, 20% para validação e 20% para teste.....	46
Tabela 9: Resultados da rede para subimagens $15 \times 15$ com 70% para treino, 15% para validação e 15% para teste.....	47
Tabela 10: Resultados da rede para subimagens $15 \times 15$ com 80% para treino, 10% para validação e 10% para teste.....	48
Tabela 11: Resultados da rede para subimagens $15 \times 15$ com 90% para treino, 5% para validação e 5% para teste.....	48
Tabela 12: Resultados da rede para subimagens $20 \times 20$ com 60% para treino, 20% para validação e 20% para teste.....	49
Tabela 13: Resultados da rede para subimagens $20 \times 20$ com 70% para treino, 15% para validação e 15% para teste.....	50
Tabela 14: Resultados da rede para subimagens $20 \times 20$ com 80% para treino, 10% para validação e 10% para teste.....	51
Tabela 15: Resultados da rede para subimagens $20 \times 20$ com 90% para treino, 5% para validação e 5% para teste.....	51
Tabela 16: Segundo teste para subimagens $15 \times 15$ com 80% para treino, 10% para validação e 10% para teste e $lr = 0,03$ .....	52
Tabela 17: Segundo teste para subimagens $15 \times 15$ com 90% para treino, 5% para validação e 5% para teste e $lr = 0,03$ . ....	53


Tabela 18: Segundo teste para subimagens $20 \times 20$ com 80% para treino, 10% para validação e 10% para teste e $lr = 0,03$ .....	53
Tabela 19: Segundo teste para subimagens $20 \times 20$ com 90% para treino, 5% para validação e 5% para teste e $lr = 0,03$ . ....	53

## 1. INTRODUÇÃO

Conhecer a subsuperfície terrestre para obter informações sobre as composições das rochas é de suma importância para a prospecção de hidrocarbonetos (petróleo e gás natural). O método sísmico, através do uso de ondas sísmicas, é o mais utilizado para obter essas informações. Dentre os métodos existentes, o método sísmico de reflexão é o mais utilizado devido a geração de informações de grandes áreas do interior terrestre, além de ser o modelo mais barato.

Com as informações obtidas da subsuperfície terrestre, são produzidas imagens para melhor representação da região estudada. Através dessas imagens, os geólogos e geofísicos buscam mapear tais regiões. Entre as estruturas mapeadas por esses especialistas, determinar precisamente regiões com maior possibilidade de concentração de hidrocarbonetos é uma tarefa que exige muito tempo e experiência, além de um alto investimento das indústrias petrolíferas. Tais investimentos algumas vezes não obtém o retorno necessário, pois as regiões identificadas pelos especialistas podem ter pouca ou nenhuma concentração de hidrocarbonetos. A automatização se faz necessário para auxiliar esses profissionais nas tomadas de decisão, além de obter maior velocidade na identificação de tais regiões e uma maior exatidão.

A Figura 1 (a) ilustra um exemplo de imagem sísmica obtida na bacia de Sergipe-Alagoas pela Agência Nacional de Petróleo (ANP). A classificação feita pelo especialista é apresentada na Figura 1 (b). A região de interesse foi destacada de amarelo.



(a)




Figura 1: Imagem sísmica da Bacia Sergipe-Alagoas. (a) Imagem Sísmica SEAL-M-567-NW, (b) classificação da imagem sísmica feita por um especialista, onde a região de interesse está destacada de amarelo. Fonte: ANP.

O objetivo deste trabalho é criar um modelo automático para identificar regiões favoráveis a concentração de hidrocarbonetos, as quais serão chamadas de regiões de interesse. O modelo consiste na utilização de redes neurais artificiais para reconhecimento de padrões em imagens sísmicas. Para auxiliar a rede neural, serão utilizados descritores de textura com abordagens estatísticas: descritores de Haralick e as funções geoestatísticas.

Este trabalho está organizado da seguinte forma: no Capítulo 2 será apresentado a fundamentação teórica das técnicas usadas. A metodologia adotada para a identificação das regiões de interesse é mostrada no Capítulo 3. No Capítulo 4 é mostrado os resultados, onde a rede neural identifica essas regiões. Finalmente, as considerações finais são apresentadas no Capítulo 5.

## **2. FUNDAMENTAÇÃO TEÓRICA**

Neste capítulo são apresentados alguns conceitos básicos necessários para o desenvolvimento desse trabalho. Inicialmente, na seção 2.1 é apresentado o método sísmico, procedimento pelo qual são obtidos os dados sísmicos. A seção 2.2 mostra conceitos básicos sobre processamento digital de imagens. As texturas e seus descritores são abordados na seção 2.3. Logo em seguida, na seção 2.4, é apresentado as Redes Neurais Artificiais que será o classificador desse trabalho. Finalmente, conceitos básicos de Reconhecimento de Padrões e também suas métricas para avaliar um classificador são mostradas na seção 2.5.

### **2.1 Método Sísmico**

O Método Sísmico tem como objetivo conhecer o interior terrestre, ou seja, é um procedimento que busca obter informações sobre as estruturas e a composição das rochas no interior da Terra. Esse procedimento é feito através da propagação de ondas sísmicas em subsuperfície.

Dentre os modelos existentes, o método direto de identificação de reservatórios de hidrocarbonetos, como a perfuração de poços, possui um elevado custo. Já os métodos indiretos de investigação são mais baratos e geram informações sobre grandes áreas da subsuperfície, onde a Sísmica de Reflexão é o método mais empregado (Barros, 2012).

#### **2.1.1 Ondas Sísmicas**

As ondas sísmicas são ondas que se propagam na terra através de terremotos, explosão de bombas ou até mesmo quando alguém joga uma pedra na água. Existem dois grupos de ondas sísmicas: Ondas de Corpo e Ondas Superficiais.

As Ondas de Corpo se propagam no interior da Terra e são divididas em Ondas P e Ondas S. As Ondas P, também chamadas de primárias, compressionais ou longitudinais, possuem o movimento das partículas na mesma direção em que a onda se propaga. São as ondas sísmicas que se movem mais rapidamente, podendo se mover através de sólidos, líquidos ou gases. Já as Ondas S, também chamadas de secundárias, cisalhamento ou transversais, possuem o movimento das partículas perpendicular a direção de propagação da onda. Elas se propagam apenas nos sólidos.

As Ondas Superficiais se propagam próximas a superfície da Terra, sendo divididas em Ondas Love e Ondas Rayleigh. Segundo Andrade (2009), nas Ondas Love as partículas vibram horizontalmente e na direção perpendicular de propagação da onda. Já nas Ondas Rayleigh, as partículas se movem de forma elíptica.

A maioria dos geólogos estão interessados nas Ondas de corpo, já que elas proporcionam muitas informações sobre a subsuperfície terrestre, onde as Ondas P são as mais utilizadas.

### 2.1.2 Método Sísmico de Reflexão

O Método Sísmico de Reflexão obtém o tempo de propagação das ondas sísmicas refletidas em subsuperfície, ou seja, tem como objetivo construir um modelo de dados através da reflexão dessas ondas.

Esse método é muito utilizado na prospecção de hidrocarbonetos (petróleo e gás natural) e de recursos minerais como carvão, minerais metálicos e energia geotérmica, além de também ser utilizado sobre a origem das rochas que compõe a crosta terrestre (Barros, 2012).

Segundo Robinson e Treitel (1980) citado no trabalho de Motta (2015), o processo de exploração de hidrocarbonetos pode ser dividido em três etapas: aquisição, processamento e interpretação, como ilustrado na Figura 2.




Figura 2: Etapas da exploração sísmica.

#### 2.1.2.1 Aquisição

Nesse processo, são utilizadas fontes artificiais para gerarem ondas sísmicas em subsuperfície atravessando diferentes camadas rochosas. Essas fontes podem ser explosões de dinamite (caso terrestre) e canhões pneumáticos (regiões marinhas). Quando as ondas encontram impedâncias acústicas diferentes entre duas camadas de rocha, ocorrem os fenômenos de refração e reflexão, ou seja, parte da onda é refratada continuando sua propagação, e a outra parte é refletida. Essa reflexão do sinal faz com que os receptores captem o tempo de retorno da onda a superfície e a sua intensidade. Os receptores podem ser os geofones para registros terrestres, e os hidrofones no caso marítimo. A Figura 3 ilustra esse processo.




Figura 3: Processo de aquisição sísmica. Adaptado de Silva (2004) citado por Motta (2015).

As informações obtidas pelos receptores são enviadas aos sismógrafos, que medem a magnitude dos sinais através de gráficos denominados sismogramas.

#### 2.1.2.2 Processamento

Nessa etapa, são produzidas imagens que melhor represente a região estudada. As informações obtidas através da aquisição sísmica serão processadas com o objetivo de corrigir alguns erros. Algumas transformações são realizadas para reorganizarem os dados a fim de formar uma fatia (caso 2D), ou uma grade tridimensional (volume sísmico). Uma das transformações realizadas nos dados faz com que as posições da fonte e do receptor sejam a mesma, ou seja, como se as ondas fossem propagadas na vertical (Barros, 2012). Segundo Figueiredo (2007) citado no trabalho de Motta (2015), outra transformação alinha os receptores, considerando-os parte de uma mesma superfície horizontal de referência.

A Figura 4 ilustra amostras de dados sísmicos, onde a sua esquerda está o traço sísmico (1D) cuja única dimensão é a temporal. A linha sísmica (2D), que é formada por vários traços sísmicos, tem uma dimensão espacial e outra temporal (Figura 4, centro). Por fim, o volume sísmico (3D) que está à direita da Figura 4, é formado por várias linhas sísmicas. Ele tem duas dimensões espaciais chamadas *inline* e *crossline*, que são direções relacionadas as fontes e os receptores, além de uma dimensão temporal






Figura 4: Amostras de dados sísmicos. Traço sísmico (esquerda), linha sísmica (centro) e volume sísmico (direita). Adaptado de Silva (2004) citado por Motta (2015).

### 2.1.2.3 Interpretação

Esta etapa tem como objetivo a elaboração do modelo geológico da região explorada, ou seja, o especialista (geólogo ou geofísico) analisa os dados sísmicos e tenta criar um modelo que mostre o que se encontra na subsuperfície estudada. A Figura 5 ilustra um modelo geológico de uma linha sísmica.




Figura 5: Modelos geológicos. Adaptado de Robinson e Treitel (1980) citado por Barros (2012).

A interpretação sísmica pode ser classificada em dois tipos: estrutural e estratigráfica. Na interpretação estrutural busca-se identificar as camadas geológicas com o objetivo principal de modelar horizontes e falhas. Já na interpretação estratigráfica, tem como foco entender a formação das camadas ao longo do tempo.

Segundo Silva (2004) citado no trabalho de Motta (2015), os horizontes sísmicos podem ser definidos como séries de reflexões contínuas de intensidades similares. Já as falhas sísmicas são fraturas de rochas em subsuperfície, ou seja, são descontinuidades nos horizontes.

É muito importante para as indústrias petrolíferas a identificação de regiões com maior possibilidade de concentração de hidrocarbonetos. No entanto, essas regiões não são facilmente identificadas pelos geólogos ou geofísicos, além de demandar bastante tempo. Portanto, faz-se necessário automatizar esse processo.

## 2.2 Processamento Digital de Imagens

Segundo Gonzalez e Woods (2000), uma imagem digital pode ser definida como uma função  $f(x, y)$ , onde  $x$  e  $y$  são coordenadas espaciais, e o valor de  $f$  é a intensidade ou nível de cinza da imagem naquele ponto  $(x, y)$ .

Um elemento de uma imagem digital é comumente chamado de pixel. Portanto, uma imagem digital é composta por vários pixels, ou seja, ela é constituída por um número finito desses elementos, onde cada um deles tem localização e valor específico.

O valor da função  $f(x, y)$  é obtido pelo produto da iluminação  $i(x, y)$  com a refletância  $r(x, y)$ , como mostra a Equação 1. A iluminação refere-se à quantidade de luz sobre os objetos da cena, e a reflexão da luz transmitida pelos objetos da cena descreve a refletância. Esses dois componentes são ilustrados na Figura 6.

$$f(x, y) = i(x, y) \cdot r(x, y) \quad (1)$$

Onde:

$$0 < i(x, y) < \infty \quad (2)$$

$$0 < r(x, y) < 1 \quad (3)$$




Figura 6: Iluminação ( $I$ ) e refletância ( $R$ ) de uma imagem. Adaptado de Marques Filho e Vieira Neto (1999).

Como o valor da iluminação é limitado (Equação 2), e o valor de refletância está entre 0 e 1 (Equação 3), então os níveis de cinza ( $L$ ) de uma imagem monocromática estarão no intervalo (denominado escala de cinza) abaixo:

$$L_{min} \leq L \leq L_{max} \quad (4)$$

onde,  $L_{min}$  e  $L_{max}$  são valores positivos e finitos.

Para digitalizar uma imagem captada por um dispositivo (câmera, scanner, satélite, entre outros), dois processos são envolvidos: amostragem e quantização.

### 2.2.1 Amostragem e Quantização de Imagens

A amostragem é a digitalização dos valores das coordenadas  $(x, y)$ . Já a quantização digitaliza os valores de intensidade (níveis de cinza) da imagem (Gonzalez e Woods, 2000). Essa digitalização transforma a imagem em uma matriz com dimensão  $M \times N$  (Equação 5), onde  $x = 0, 1, \dots, M - 1$  e  $y = 0, 1, \dots, N - 1$ .

$$f(x, y) = \begin{bmatrix} f(0, 0) & f(0, 1) & \dots & f(0, N - 1) \\ f(1, 0) & f(1, 1) & \dots & f(1, N - 1) \\ \vdots & \vdots & \ddots & \vdots \\ f(M - 1, 0) & f(M - 1, 1) & \dots & f(M - 1, N - 1) \end{bmatrix} \quad (5)$$

Os valores de cada elemento da matriz na Equação 5 são números inteiros. A Figura 7 (a) exemplifica uma imagem com níveis de cinza de 0 (preto) a 255 (branco). A digitalização dessa imagem, em formato de matriz, é mostrada na Figura 7 (b).




Figura 7: Imagem Digital. (a) Imagem em níveis de cinza  $4 \times 4$ , (b) digitalização da imagem.

## 2.3 Textura

A textura fornece informações de extrema importância para o reconhecimento de objetos ou regiões em uma imagem, pois concentra-se na correlação espacial entre as variações dos níveis de cinza.

Três abordagens principais são usadas para classificar imagens para descrição de textura: estatística, estrutural e espectral. A abordagem estatística baseia-se em medidas locais extraídas do padrão, já a abordagem estrutural usa a ideia de que as texturas são compostas de primitivas dispostas, e a abordagem espectral baseia-se na transformada de Fourier (Nascimento, 2003).

Nesse trabalho são usadas abordagens estatísticas para descrição de textura, pois ela fornece regras estatísticas que definem as relações e distribuições entre os níveis de cinza de uma imagem.

Dois descritores de texturas foram utilizados neste trabalho: os descritores de Haralick e os descritores geoestatísticos.

### 2.3.1 Descritores de Haralick

Haralick et al. (1973) desenvolveram descritores de textura para classificação em imagens baseados em estatísticas de segunda ordem, ou seja, descritores que se baseiam no relacionamento espacial entre os níveis de cinza de uma imagem

Os descritores de Haralick se baseiam a partir da matriz de coocorrência de uma imagem, que são matrizes que consideram a relação entre dois pixels por vez, onde um é chamado de pixel de referência e o outro de pixel vizinho. Esses pixels são separados por uma distância  $d$  e um ângulo  $\theta$ . Normalmente usam-se quatro ângulos:  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  e  $135^\circ$ , como mostra a Figura 8.




Figura 8: Ângulos normalmente utilizados para obtenção da matriz de coocorrência.

Então, pode-se definir a matriz de coocorrência  $P(i, j, d, \theta)$  de uma matriz (ou imagem)  $A$  como a frequência ocorrida entre dois pares de pixels separados por uma distância  $d$  e um ângulo  $\theta$ , onde um pixel tem nível de cinza  $i$  e o outro tem nível de cinza  $j$ . A Figura 9 ilustra a obtenção da matriz de coocorrência  $P(i, j, 1, 0^\circ)$  de uma imagem com 4 níveis de cinza. O elemento  $p(0,0)$  da matriz é igual a 2 (Figura 9, direita), pois essa é a frequência ocorrida quando o pixel de referência e o pixel vizinho valem 0 (Figura 9, esquerda). Esse procedimento se repete para os demais elementos da matriz.




Figura 9: Obtenção da matriz de coocorrência  $P(i, j, 1, 0^\circ)$  de uma imagem com 4 níveis de cinza. Representação matricial da imagem (esquerda), resultado da matriz de coocorrência (direita).

Para usar os descritores de Haralick é preciso normalizar a matriz de coocorrência, obtendo assim a matriz de probabilidade  $P(i, j)$ , como mostra a Equação 6.

$$P(i,j) = \frac{p(i,j)}{\sum_{i=0}^{N_g} \sum_{j=0}^{N_g} p(i,j)} \quad (6)$$

onde,  $p(i,j)$  são os elementos da matriz de coocorrência e  $N_g$  é o número total de níveis do atributo.

Como exemplo da Equação 6, segue abaixo a matriz de probabilidade  $P(i,j)$  obtida através da normalização da matriz de coocorrência  $P(i,j, 1, 0^\circ)$  da Figura 9 (direita).

$$P(i,j) = \begin{bmatrix} 0,1 & 0,1 & 0,05 & 0 \\ 0 & 0,2 & 0 & 0 \\ 0 & 0 & 0,25 & 0,1 \\ 0 & 0 & 0 & 0,2 \end{bmatrix}$$

Abaixo são ilustradas as matrizes de coocorrência e suas respectivas matrizes de probabilidade da imagem na Figura 9 (esquerda), para  $d = 1$  e para os demais ângulos ( $\theta = 45^\circ, 90^\circ, 135^\circ$ ).

$$P(i,j, 1, 45^\circ) = \begin{bmatrix} 2 & 1 & 0 & 0 \\ 0 & 2 & 0 & 0 \\ 0 & 3 & 3 & 1 \\ 0 & 0 & 2 & 2 \end{bmatrix} \quad P(i,j) = \begin{bmatrix} 0,12 & 0,06 & 0 & 0 \\ 0 & 0,12 & 0 & 0 \\ 0 & 0,18 & 0,18 & 0,06 \\ 0 & 0 & 0,12 & 0,12 \end{bmatrix}$$

$$P(i,j, 1, 90^\circ) = \begin{bmatrix} 3 & 0 & 0 & 0 \\ 0 & 3 & 0 & 0 \\ 2 & 3 & 3 & 0 \\ 0 & 0 & 3 & 3 \end{bmatrix} \quad P(i,j) = \begin{bmatrix} 0,15 & 0 & 0 & 0 \\ 0 & 0,15 & 0 & 0 \\ 0,1 & 0,15 & 0,15 & 0 \\ 0 & 0 & 0,15 & 0,15 \end{bmatrix}$$

$$P(i,j, 1, 135^\circ) = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 1 & 2 & 0 & 0 \\ 3 & 2 & 1 & 0 \\ 0 & 0 & 4 & 2 \end{bmatrix} \quad P(i,j) = \begin{bmatrix} 0,06 & 0 & 0 & 0 \\ 0,06 & 0,12 & 0 & 0 \\ 0,18 & 0,12 & 0,06 & 0 \\ 0 & 0 & 0,25 & 0,12 \end{bmatrix}$$

Neste trabalho foi usada a distância  $d = 1$  e todos os ângulos já citados para obtenção das matrizes de coocorrência. Além disso, dentre os descritores de Haralick, cinco deles foram utilizados: Segundo Momento Angular, Entropia, Contraste, Variância e Homogeneidade. Esses descritores são apresentados nas Equações 7, 8, 9, 10, 11 e 14:

*Segundo Momento Angular:* Expressa a uniformidade local dos níveis de cinza de uma imagem.

$$SMA(d, \theta) = \sum_{i=0}^{N_g} \sum_{j=0}^{N_g} [P(i, j)]^2 \quad (7)$$

*Entropia:* Grau de dispersão (ou desordem) nos níveis de cinza de uma imagem.

$$Ent(d, \theta) = - \sum_{i=0}^{N_g} \sum_{j=0}^{N_g} P(i, j) \cdot \log [P(i, j)] \quad (8)$$

*Contraste:* Fornece a diferença entre os níveis de cinza de pares de pixels.

$$Cont(d, \theta) = \sum_{i=0}^{N_g} \sum_{j=0}^{N_g} (i - j)^2 \cdot P(i, j) \quad (9)$$

*Variância:* Medida de heterogeneidade da matriz de coocorrência, ou seja, mede a dispersão dos dados em torno do nível de cinza médio.

$$var_x(d, \theta) = \sum_{i=0}^{N_g} \sum_{j=0}^{N_g} (i - \mu_x)^2 \cdot P(i, j) \quad (10)$$

$$var_y(d, \theta) = \sum_{i=0}^{N_g} \sum_{j=0}^{N_g} (j - \mu_y)^2 \cdot P(i, j) \quad (11)$$

Onde:

$$\mu_x = \sum_{i=0}^{N_g} i \cdot P(i, *) \quad (12)$$

$$\mu_y = \sum_{j=0}^{N_g} j \cdot P(*, j) \quad (13)$$

*Homogeneidade*: Assume valores altos quando ocorre níveis de cinza similares em pares de pixels.

$$Hom(d, \theta) = \sum_{i=0}^{N_g} \sum_{j=0}^{N_g} \frac{1}{1 + (i - j)^2} \cdot P(i, j) \quad (14)$$

### 2.3.2 Descritores Geoestatísticos

Os descritores geoestatísticos, também chamados de funções geoestatísticas, descrevem o relacionamento entre um conjunto de pares de pontos de uma amostra através da variabilidade e da correlação espacial. Segundo Isaaks e Srivastava (1989) citado no trabalho de Sousa (2006), quanto maior a proximidade entre os pares de pontos, maior será sua similaridade, e quanto menor a proximidade, menor será sua similaridade.

As funções geoestatísticas separam os pares de amostras por uma distância e uma direção através de um vetor  $h$ . A Figura 10 (a) ilustra a separação de duas amostras através do vetor  $h$ , onde  $x_i$  é a amostra de origem e  $x_i + h$  é a extremidade da amostra. Neste exemplo, as amostras são pixels. Já a Figura 10 (b) apresenta todos os números de pares  $N$  do vetor  $h$ .




Figura 10: Representação do vetor  $h$ . (a) Ilustração da separação de dois pixels pelo vetor  $h$ , (b) todos os  $N$  pares do vetor  $h$ .

Neste trabalho foram usadas as funções semivariograma, semimadograma e covariograma. Nessas funções as amostras são definidas por uma função aleatória  $Z(u)$ , onde nos dados sísmicos,  $Z(u)$  representa a amplitude sísmica de cada amostra  $u$ . Essas funções são apresentadas nas Equações 15, 16 e 17:



*Semivariograma*: Mede o grau de dependência entre os pares de pontos de uma amostra a partir da diferença quadrada de suas intensidades.

$$\gamma(h) = \frac{1}{2N} \sum_{i=1}^N [Z(x_i) - Z(x_i + h)]^2 \quad (15)$$

*Semimadograma*: É semelhante a função semivariograma, exceto que a dependência entre os pares de pontos de uma amostra é medida pela diferença absoluta de suas intensidades.

$$m(h) = \frac{1}{2N} \sum_{i=1}^N |Z(x_i) - Z(x_i + h)| \quad (16)$$

*Covariograma*: É uma medida de correlação entre duas variáveis.

$$C(h) = \frac{1}{2N} \sum_{i=1}^N [Z(x_i)Z(x_i + h) - m_{-h} \cdot m_{+h}] \quad (17)$$

Onde:

$$m_{-h} = \frac{1}{N} \sum_{i=1}^N Z(x_i) \quad (18)$$

$$m_{+h} = \frac{1}{N} \sum_{i=1}^N Z(x_i + h) \quad (19)$$

## 2.4 Redes Neurais Artificiais

As Redes Neurais Artificiais (RNA) são modelos computacionais baseados na biologia, mais especificamente nos neurônios cerebrais, onde elas tentam se assemelhar aos meios de conexão desses neurônios, pois os mesmos têm a capacidade de aprender e tomar decisões baseadas em informações.

A capacidade de aprender através de exemplos e de generalizar a informação aprendida é o atrativo principal para solução de problemas utilizando RNAs (Braga et al., 2007). Essa

generalização que a rede é capaz de fazer consiste em resolver problemas por si através do conhecimento adquirido, ou seja, ela estima soluções para dados desconhecidos.

### 2.4.1 Neurônio Biológico

Um neurônio biológico, ilustrado na Figura 11, pode ser dividido em três partes principais: dendritos, corpo celular e o axônio. Os dendritos são responsáveis por receber os sinais (informações) de um certo local, que pode ser outros neurônios ou o meio externo. Esses sinais são processados pelo corpo celular, onde novos impulsos elétricos são gerados. O axônio transmite esses impulsos para as terminações sinápticas, o qual vai repassá-los para outros neurônios. A conexão entre as terminações sinápticas de um neurônio e os dendritos do outro chama-se sinapse.




Figura 11: Neurônio Biológico. Adaptado de Silva et al. (2010).

As conexões desses neurônios através das sinapses formam as redes neurais biológicas, as quais são responsáveis por todo funcionamento do cérebro humano.

### 2.4.2 Neurônio Artificial

Segundo Silva et al. (2010), o modelo de neurônio artificial mais simples e que engloba as principais características de um neurônio biológico foi proposto por McCulloch & Pitts (1943), sendo ainda o modelo mais utilizado nas diferentes arquiteturas de redes neurais artificiais.

Um neurônio artificial, como mostra a Figura 12, é composto por vários sinais de entrada ( $x_1, x_2, \dots, x_n$ ), que são as informações do problema, os quais são ponderados pelos pesos

sinápticos ( $w_1, w_2, \dots, w_n$ ), onde o resultado é dado como entrada para o neurônio. Essa ponderação determina o grau de relevância de cada entrada ( $x_i$ ) do neurônio. Logo em seguida, a função agregadora ( $\Sigma$ ) realiza a soma dos sinais de entrada que foram ponderados pelos pesos sinápticos, onde seu resultado é ponderado por uma constante ( $\theta$ ) chamada de limiar de ativação. Por fim, o potencial de ativação ( $\mu$ ) é o resultado obtido pela diferença entre o valor produzido pela função agregadora e o limiar de ativação (Equação 20), o qual é encaminhado para a função de ativação ( $\varphi$ ) cujo objetivo é modifica-lo, limitando-o dentro de um intervalo com valores razoáveis. Essa função de ativação é responsável pela saída ( $y$ ), mostrada na Equação 21, que corresponde ao valor final produzido pelo neurônio.




Figura 12: Neurônio Artificial.

$$\mu = \sum_{i=1}^n w_i \cdot x_i - \theta \quad (20)$$

$$y = \varphi(\mu) \quad (21)$$

As funções de ativação mais comuns são apresentadas na Figura 13. A função degrau, como mostra a Figura 13 (a) e a Equação 22, limita os valores do potencial de ativação entre 0 e 1. Uma aproximação contínua da função degrau é a função sigmoideal, apresentada na Figura 13 (b) e Equação 23. A função linear, ilustrada na Figura 13 (c) e Equação 24, resulta em valores iguais aos do potencial de ativação. Pode-se obter também os valores do potencial de ativação limitados entre -1 e 1, o qual é feito pela função tangente hiperbólica apresentada na Figura 13 (d) e a Equação 25.

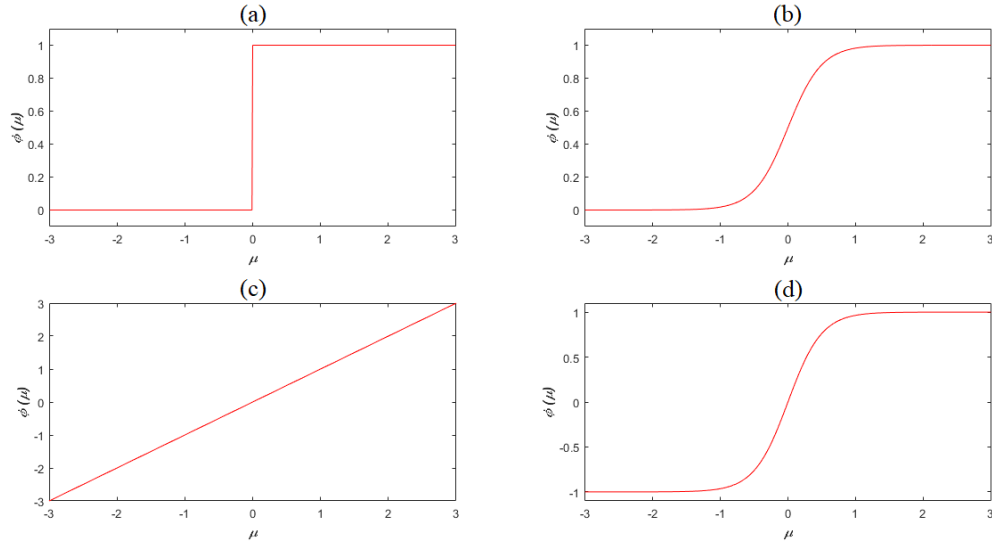


Figura 13: Funções de ativação. (a) Degrau, (b) sigmoidal, (c) linear, (d) tangente hiperbólica.

$$\varphi(\mu) = \begin{cases} 1, & \text{se } \mu \geq 0 \\ 0, & \text{se } \mu < 0 \end{cases} \quad (22)$$

$$\varphi(\mu) = \frac{1}{1 + e^{-\beta\mu}} \quad (23)$$

$$\varphi(\mu) = \mu \quad (24)$$

$$\varphi(\mu) = \frac{1 - e^{-\beta\mu}}{1 + e^{-\beta\mu}} \quad (25)$$

onde,  $\beta$  é a inclinação da função.

### 2.4.3 Arquiteturas de Redes Neurais

Neurônios individuais possuem capacidade computacional limitada, mas um conjunto de neurônios artificiais conectados na forma de uma rede é capaz de resolver problemas de complexidade elevada (Braga et al., 2007). A arquitetura de uma rede neural define como será a conexão entre esse conjunto de neurônios.

Divide-se basicamente a arquitetura de uma rede neural em três partes (camadas): camada de entrada, camadas ocultas ou intermediária e camada de saída. A camada de entrada é responsável por receber as informações do problema (sinais). As camadas que são compostas

por neurônios são as camadas ocultas e a de saída, onde nas camadas ocultas ocorre todo o processamento interno da rede, além de conferir a mesma uma maior capacidade computacional, já na camada de saída são apresentados os resultados obtidos pela rede.

A arquitetura de uma rede pode variar tanto no número de camadas que a mesma possui, quanto no número de neurônios em cada camada. Além disso, cada camada pode ter funções de ativação diferente.

A Figura 14 ilustra duas arquiteturas de redes neurais. A estrutura mais simples é apresentada na Figura 14 (a), a qual é composta por uma camada de entrada e pela camada de saída. Já na Figura 14 (b) é apresentada uma arquitetura com camadas múltiplas, pois além das camadas de entrada e saída, ela é composta também por camadas ocultas.




Figura 14: Arquiteturas de redes neurais. (a) Arquitetura de camada única, (b) arquitetura de camadas múltiplas. Adaptado de Silva et al. (2010).

## 2.4.4 Aprendizado

Um dos aspectos mais relevantes de uma rede neural é sua capacidade de aprender através de exemplos e em seguida apresentar soluções de exemplos jamais vistos. O treinamento é feito através de algoritmos de aprendizagem cujo objetivo é ajustar os pesos sinápticos da rede.

Para poder saber se o aprendizado está sendo útil, divide-se normalmente o conjunto de dados em dois subconjuntos: treinamento e teste. O subconjunto de treinamento é usado para o aprendizado da rede, onde ele pode ter seus dados divididos em um subconjunto de validação, que faz verificações iniciais durante essa fase de aprendizagem. Já o subconjunto de teste avalia a performance da rede, verificando se a sua generalização apresenta respostas aceitáveis.

O aprendizado da rede pode ser feito através do aprendizado supervisionado ou não supervisionado. No aprendizado supervisionado é disponibilizado para a rede tanto o conjunto de dados de entrada quanto a saída desejada. Os pesos da rede são ajustados para que a saída

dela se aproxime da saída desejada. Já no aprendizado não supervisionado, são disponibilizados apenas os dados de entrada, o que faz com que a rede precise se auto organizar com relação a existência de regularidades nesses dados. Neste trabalho foi utilizado o aprendizado supervisionado.

## 2.5 Reconhecimento de Padrões

Os seres humanos têm facilidade em reconhecer alguns aspectos da realidade (imagens, sons, leitura e escrita, sensação tátil, etc.) através de informações recebidas do meio ambiente pelos seus sentidos.

Reconhecer padrões consiste basicamente em identificar características em objetos e classificá-los como pertencentes a uma determinada categoria ou classe. A Figura 15 ilustra um classificador (que neste trabalho é uma rede neural) identificando um objeto desconhecido sendo atribuído a uma classe B.



Figura 15: Classificação de um objeto desconhecido a uma determinada classe.

Alguns exemplos de sistemas automáticos para reconhecimento de padrões são o reconhecimento de faces, fala, escrita, identificação de sequências de DNA, classificação de documentos em categorias, entre outros.

### 2.5.1 Etapas do Reconhecimento de Padrões

Segundo Marques Filho e Vieira Neto (1999), os sistemas de reconhecimento de padrões podem ser divididos nas etapas apresentadas na Figura 16:




Figura 16: Etapas de um sistema de reconhecimento de padrões.

#### 2.5.1.1 Aquisição de Dados

O primeiro passo para um sistema de reconhecimento de padrões é a aquisição de dados, que é onde os dados são captados por um dispositivo (câmera, scanner, tomógrafo médico, satélite, sismógrafo, etc.), o qual deve ter características apropriadas ao tipo de sistema que está sendo desenvolvido. Neste trabalho os dados obtidos nesta etapa são as imagens sísmicas.

#### 2.5.1.2 Pré-Processamento

As operações efetuadas nesta etapa são ditas de baixo nível, pois trabalham diretamente com os valores de intensidade dos pixels (Marques Filho e Vieira Neto, 1999). Consiste na maior parte das transformações da imagem, cujo objetivo é melhorar a qualidade da imagem realizando a diminuição ou eliminação de imperfeições decorrentes do processo de aquisição.

#### 2.5.1.3 Segmentação

Esta etapa tem como objetivo identificar as áreas de interesse quem compõem uma imagem, ou seja, é um processo que divide a imagem em várias regiões mudando sua representação e facilitando sua análise. Geralmente segmenta-se a imagem com base nas propriedades de cores dos pixels, intensidade, entre outros.

Um procedimento de segmentação bem-sucedido aumenta as chances de sucesso na solução de problemas. Já segmentações inconsistentes quase sempre asseguram falha no processo. Em geral, quanto mais precisa for a segmentação, maiores são as chances de sucesso no reconhecimento de padrões (Gonzalez & Woods, 2000).

#### 2.5.1.4 Extração de Características

Nesta etapa são retiradas características dos objetos que facilitem sua identificação, diminuindo informações redundantes e como consequência reduzindo a dimensionalidade dos dados.

Segundo Duda et al. (2001) citado no trabalho de Motta (2015), o objetivo dessa etapa é caracterizar um objeto a ser classificado utilizando medidas cujos valores sejam muito similares a objetos de uma determinada categoria, e muito diferentes a objetos de categorias diferentes.

#### 2.5.1.5 Classificação

Nesta etapa o classificador vai decidir a que classe o objeto pertence. Como a classificação na maioria dos casos é imperfeita, faz-se necessário medidas que avaliem o desempenho do classificador. Neste trabalho utilizou-se algumas medidas estatísticas que são baseadas na matriz de confusão, apresentada na Tabela 1. Utiliza-se esse tipo de medida em aprendizado supervisionado.

Tabela 1: Matriz de confusão.

		Resultado Previsto	
		Classe A	Classe B
Resultado Real	Classe A	VP	FN
	Classe B	FP	VN

A Tabela 1 compara as respostas geradas pelo classificador (colunas da tabela) versus as respostas reais (linhas da tabela) previamente conhecidas. Na diagonal principal constitui o caso em que os objetos foram classificados corretamente, os quais são chamados de verdadeiro positivo (VP) e verdadeiro negativo (VN). Um objeto da classe A classificado corretamente como pertencente a essa classe constitui o caso de verdadeiro positivo, analogamente, um objeto da classe B classificado corretamente como pertencente a essa classe constitui o caso de verdadeiro negativo. Os demais elementos da matriz são os objetos que foram classificados erroneamente, sendo chamados de falso negativo (FN) e falso positivo (FP). Um objeto da



classe A classificado incorretamente como pertencente a classe B constitui o caso de falso negativo, da mesma forma, um objeto da classe B classificado erroneamente como pertencente a classe A constitui o caso de falso positivo.

Nesse trabalho utilizou-se as medidas de acurácia, sensibilidade, especificidade, precisão e  $F_1$  score. A acurácia, apresentada na Equação 26, mede a probabilidade de os objetos serem classificados corretamente em suas respectivas classes.

$$Acurácia = \frac{VP + VN}{VP + VN + FP + FN} \quad (26)$$

É necessário que a quantidade de dados de cada classe esteja balanceada, ou seja, ter muitos objetos de uma classe A e poucos de uma classe B (ocorrendo o desbalanceamento) fará com que o classificador identifique qualquer objeto como pertencente a classe A, possivelmente resultando em uma acurácia com um valor alto. Com o objetivo de lidar com esse problema técnicas como a sensibilidade e especificidade foram desenvolvidas.

A sensibilidade, mostrada na Equação 27, mede a porcentagem de objetos positivos sendo classificados corretamente sobre o total de objetos realmente positivos. De maneira similar, a especificidade mede a probabilidade de objetos negativos serem classificados corretamente sobre o total de objetos realmente negativos, como mostra a Equação 28.

$$Sensibilidade = \frac{VP}{VP + FN} \quad (27)$$

$$Especificidade = \frac{VN}{VN + FP} \quad (28)$$

Alterando parâmetros de um classificador, é possível aumentar a sensibilidade ao custo da diminuição da especificidade, e vice-versa. A Curva ROC (*Receiver Operating Characteristic Curve*) é um modo de avaliar visualmente a compensação entre a sensibilidade e a especificidade (Motta, 2015). A Figura 17 ilustra uma Curva ROC, onde a curva é criada através da projeção entre a taxa de falso positivo e a taxa de falso negativo. Essas taxas variam entre 0 e 1 e a área sob a Curva ROC representa o desempenho do classificador. Um bom classificador sempre terá sua curva acima da curva azul, consequentemente obtendo uma área superior a 0,5. Por fim, um classificador perfeito teria uma área igual a 1.




Figura 17: Exemplo de uma curva ROC.

A precisão, dada pela Equação 29, mede a probabilidade de objetos positivos classificados corretamente sobre um total de objetos classificados como positivos.

$$Precisão = \frac{VP}{VP + FP} \quad (29)$$

O  $F_1$ score, apresentado na Equação 30, é uma medida ponderada entre precisão e sensibilidade que indica a qualidade geral do classificador.

$$F_1score = \frac{2 \times precisão \times sensibilidade}{precisão + sensibilidade} \quad (30)$$

### 3. METODOLOGIA

Nessa etapa são apresentados todos os materiais e métodos necessários para a classificação de regiões favoráveis a concentração de hidrocarbonetos (regiões de interesse) em imagens sísmicas através de uma rede neural artificial. Na seção 3.1 é apresentada a etapa de aquisição de imagens e da geração de subimagens. A seção 3.2 mostra como é feita a normalização dos descritores de Haralick e das funções geoestatísticas. Logo em seguida, na seção 3.3, é apresentado a formação dos dados de entrada e saída que são enviados a rede neural. Finalmente, a arquitetura utilizada na rede neural e também o algoritmo utilizado é apresentado na seção 3.4. Além disso, foi utilizado neste trabalho o software MATLAB<sup>®</sup>.

#### 3.1 Aquisição de Imagens

Nesta etapa foi obtido um banco de imagens da bacia de Sergipe-Alagoas pela Agência Nacional de Petróleo, Gás Natural e Biocombustíveis (ANP) em sua 13<sup>a</sup> rodada de Licitações de Petróleo e Gás. Esse banco possui um total de 4 imagens com dimensões:  $575 \times 855$ ,  $499 \times 1062$ ,  $632 \times 1315$  e  $637 \times 1318$ . Uma dessas imagens é apresentada na Figura 18.




Figura 18: Imagem Sísmica SEAL-M-567-NW com dimensão  $575 \times 855$ . Fonte: ANP.

Dentre as imagens obtidas, algumas possuem escala de 1:4 km e outras possuem escala de 1:5 km. Sendo assim foi necessário normalizá-las, cuja escala escolhida foi a de 1:4 km.

### 3.1.1 Geração de Subimagens

Para auxiliar no treinamento da rede neural, as imagens foram subdivididas em blocos (subimagens) para melhor obtenção das informações de textura. Por exemplo, subdividindo a imagem da Figura 18 em blocos com dimensão  $10 \times 10$ , resultará em um total de 4.845 subimagens. Ao somar todas as 4 imagens, será obtido um total de 26.545 subimagens de tamanho  $10 \times 10$ . Neste trabalho, além da dimensão  $10 \times 10$ , foram utilizadas as dimensões  $15 \times 15$  e  $20 \times 20$ , cujo total de subimagens foi 11.784 e 6.478, respectivamente. Haverá perda de informação nas bordas através dessa geração, o que não influenciará nos resultados obtidos pela rede, pois as informações mais importantes e em grande quantidade encontram-se no meio das imagens. A Figura 19 ilustra a geração das subimagens.






Figura 19: Geração das subimagens.

Logo em seguida, é necessário saber qual das subimagens contém as regiões de interesse. Para isso, utilizou-se as classificações já feitas pelos geólogos ou geofísicos do banco de imagens desse trabalho. Como exemplo, a Figura 20 (a) apresenta uma imagem cujas regiões foram identificadas por um profissional da área, onde a cor amarela indica onde estão as regiões de interesse. A extração da área pintada de amarelo, é ilustrada na Figura 20 (b).



(a)



(b)

Figura 20: Obtenção das regiões de interesse. (a) Imagem com regiões já classificadas, (b) extração da região de interesse.

A partir dessa extração é possível saber quais das subimagens geradas estão nas regiões de interesse. Para isso foi considerado que, se uma subimagem possuir mais de 10 pixels de cor branca, a mesma será considerada como uma dessas regiões. A Figura 21 mostra as subimagens que satisfazem essa condição.




Figura 21: Obtenção das subimagens contidas na região de interesse.

A Figura 22 mostra um exemplo de uma subimagem (destacada de vermelho) que possui pixels com cores brancas, mas não em quantidades suficientes para ser considerada uma subimagem contendo regiões de interesse, ou seja, essa subimagem não possui mais de 10 pixels com cor branca.




Figura 22: Exemplo de subimagem que não possui mais de 10 pixels com cor branca.

Finalmente, foi obtido a quantidade de subimagens que contém regiões de interesse e a quantidade delas que não contém. Por exemplo, a imagem da Figura 18, quando dividida em subimagens com dimensão  $10 \times 10$ , possui 176 blocos com essas regiões. Somando todas as 4

imagens com essa dimensão, resultará em 713 subimagens contendo tais regiões de interesse. A Tabela 2 mostra o resultado desse procedimento para todas as dimensões.

Tabela 2: Total de subimagens contidas nas regiões de interesse e não contidas.

<b>Dimensão das Subimagens</b>	<b>Total de Subimagens com regiões de interesse</b>	<b>Total de Subimagens sem regiões de interesse</b>	<b>Total de Subimagens</b>
<b>10 × 10</b>	713	25.832	26.545
<b>15 × 15</b>	404	11.380	11.784
<b>20 × 20</b>	270	6.208	6.478

Como a quantidade de dados em cada categoria está desproporcional, fez-se necessário balanceá-los. Esse procedimento foi feito obtendo aleatoriamente (do total de subimagens de uma dimensão) metade de blocos com regiões de interesse e metade de blocos sem essas regiões. Por exemplo, a dimensão 10 × 10 cujo total de subimagens é 26.545, terá um total de 13.272 blocos com regiões de interesse e 13.272 blocos sem essas regiões. O mesmo procedimento é feito para as demais dimensões, onde são geradas 5.892 subimagens para cada classe na dimensão 15 × 15, e 3.239 blocos para cada categoria na dimensão 20 × 20.

### 3.2 Normalização dos Dados

Nesta etapa foi obtido os valores dos descritores de Haralick (Segundo Momento Angular, Entropia, Contraste, Variância e Homogeneidade) e das funções geoestatísticas (semivariograma, semimadograma e covariograma) para cada subimagem.

A escolha desses 5 descritores de Haralick em um total de 14, se deu por um estudo feito por Andrea Baraldi e Flavio Parmiggiani (1995), o qual resultou que esses descritores são os mais relevantes. Para calcular os descritores de Haralick utilizou-se os ângulos  $\theta$  iguais a: 0°, 45°, 90° e 135°, e a distância  $d$  entre os pixels igual a 1. Os mesmos ângulos foram utilizados para as funções geoestatísticas. Maiores detalhes desses descritores na seção 2.3.

É necessário normalizar os valores dos descritores, ou seja, deixá-los na mesma escala, pois se fossem utilizados seus valores brutos a rede neural seria tendenciosa aos valores mais

altos. O objetivo nesta normalização é obter uma igualdade no treinamento da rede em relação aos descritores através de uma transformação (Equação 31) que se baseia na média e no desvio padrão do conjunto de dados.

$$Z = \frac{x - \bar{x}}{\sigma} \quad (31)$$

Onde:

$x$ : valor do descritor


$\bar{x}$ : média do conjunto de valores a serem normalizados

$\sigma$ : desvio padrão

$Z$ : valor normalizado.

Como exemplo dessa transformação, a Figura 23 mostra 4 imagens fictícias com seus três descritores fictícios calculados, onde os descritores 1 e 3 possuem valores bem mais altos em comparação ao descritor 2 (Figura 23, esquerda). A normalização desses valores, utilizando a Equação 31, é apresentado na direita da Figura 23. É possível notar que a diferença dos valores entre os descritores 1 e 3 com relação ao descritor 2 caiu muito. Para garantir que essa transformação está correta, a média e o desvio padrão tem valores 0 e 1, respectivamente.

Imagens	Descritor 1	Descritor 2	Descritor 3
Imagem 1	4,50	1,1	5,5
Imagem 2	7,00	1,8	8,2
Imagem 3	3,50	1,3	5,4
Imagem 4	6,80	1,5	5,2
Média	5,45	1,425	6,075
Desvio Padrão	1,4942	0,2586	1,2316



Imagens	Descritor 1	Descritor 2	Descritor 3
Imagem 1	-0,6358	-1,2568	-0,4669
Imagem 2	1,0374	1,4501	1,7254
Imagem 3	-1,3051	-0,4834	-0,5481
Imagem 4	0,9035	0,29	-0,7104
Média	0	0	0
Desvio Padrão	1	1	1

Figura 23: Transformação dos dados. Descritores com valores originais (esquerda), normalização dos descritores (direita).

### 3.3 Dados de Entrada e Saída

O primeiro passo para formação dos dados de entrada da rede neural consistiu em transformar as matrizes de cada subimagem em vetores. Por exemplo, para a dimensão  $10 \times 10$ , a matriz  $M_1$ , que representa uma subimagem nesta dimensão, é transformada em um vetor



$v_1$  com 100 coordenadas (Figura 24), onde  $x_1, x_2, \dots, x_{100}$  são os níveis de cinza de cada pixel. Analogamente, as subimagens de dimensão  $15 \times 15$  são transformadas em vetores com 225 coordenadas e os blocos com dimensão  $20 \times 20$  são alterados para vetores de 400 coordenadas.

$$M_1 = \begin{bmatrix} x_1 & \cdots & x_{100} \\ \vdots & \ddots & \vdots \\ x_{91} & \cdots & x_{100} \end{bmatrix} \Rightarrow v_1 = [x_1, x_2, \dots, x_{100}]$$

Figura 24: Transformação de uma subimagem em um vetor.

Logo em seguida, é necessário adicionar os valores dos descritores de Haralick e das funções geoestatísticas nas posições finais dos vetores que representam as subimagens. Com relação aos descritores de Haralick, são adicionados ao final de cada vetor 24 novos valores, pois a variância calcula-se tanto em  $x$  quanto em  $y$ , e além disso são utilizados 4 ângulos ( $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  e  $135^\circ$ ) para cada descritor, com a distância  $d = 1$ . Já para cada função geoestatística, foram utilizados os mesmos ângulos dos descritores de Haralick, mas a distância  $h$  vai de 1 até  $n - 1$ , onde  $n$  é a dimensão da subimagem. Por exemplo, para o vetor  $v_1$  da Figura 24, são adicionados em seu final 132 valores, onde 24 desses valores são obtidos pelos descritores de Haralick e 108 são calculados pelas funções geoestatísticas, como é mostrado abaixo.

$$v_1 = [x_1, x_2, \dots, x_{100}, d_1, d_2, \dots, d_{132}]$$

onde,  $d_1, d_2, \dots, d_{132}$ , são os valores dos descritores.

Portanto, as subimagens com dimensão  $10 \times 10$  resultaram em vetores com 232 coordenadas. Já nas subimagens com dimensão  $15 \times 15$ , os vetores tem 417 coordenadas ( $225+24+168$ ). Por fim, os vetores resultam em 652 coordenadas ( $400+24+228$ ) nas subimagens com dimensão  $20 \times 20$ .

Os dados de entrada para a rede neural será uma matriz composta por esses vetores, cuja quantidade de linhas é o número total de subimagens. Por exemplo, para a dimensão  $10 \times 10$  a matriz de entrada tem 26.544 linhas, como é apresentado abaixo.

$$M_{entrada} = \begin{bmatrix} v_1 \\ v_2 \\ \vdots \\ v_{26.544} \end{bmatrix}$$

Analogamente, as dimensões  $15 \times 15$  e  $20 \times 20$  enviam como entrada para a rede matrizes com 11.784 e 6.478 linhas, respectivamente.

A saída desejada para a rede neural é uma matriz, cuja quantidade de linhas vai depender da dimensão utilizada nos dados de entrada, e as colunas são: [1 0] quando a subimagem contém regiões de interesse e [0 1] caso contrário.

### 3.4 Arquitetura da Rede Neural

A arquitetura da rede consiste na camada de entrada, em uma camada oculta e na camada de saída. É enviado para a camada de entrada uma matriz com todas as subimagens de uma determinada dimensão. Na camada de saída também é enviado uma matriz contendo as saídas desejadas para cada subimagem. Ambas as matrizes (entrada e saída) são explicadas na seção 3.3. A camada oculta possui 50 neurônios, os quais foram escolhidos baseados em arquiteturas de artigos semelhantes e também através de testes com outras configurações, onde essa quantidade obteve melhores resultados. Além disso, foi escolhido (para esta camada) a função de ativação tangente hiperbólica para limitar os valores dos dados de entrada entre -1 e 1. A opção por essa função consiste no fato de que os dados de entrada possuem valores positivos e negativos. A Figura 25 apresenta a arquitetura da rede usando todas as dimensões. A rede neural com a dimensão  $10 \times 10$  é mostrado na Figura 25 (a), já a dimensão  $15 \times 15$  é ilustrado na Figura 25 (b), e a dimensão  $20 \times 20$  é apresentado na Figura 25 (c).

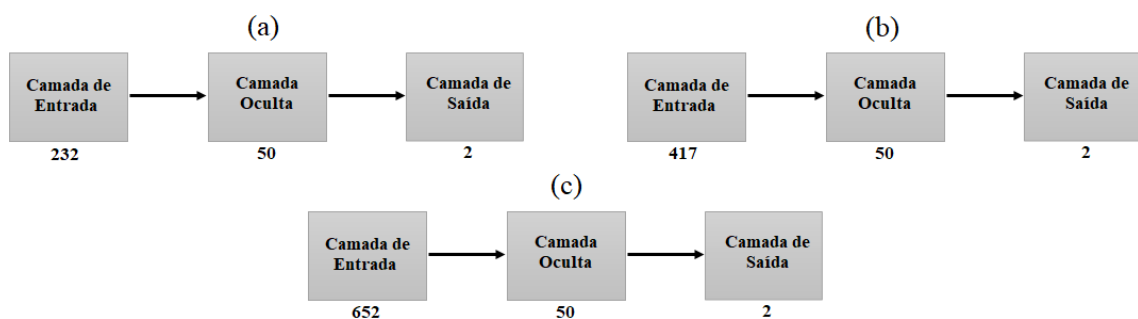


Figura 25: Arquitetura da rede em dimensões diferentes. (a) Dimensão  $10 \times 10$ , (b) dimensão  $15 \times 15$ , (c) dimensão  $20 \times 20$ .

O algoritmo utilizado para o treinamento da rede foi o Backpropagation com gradiente descendente estocástico, o qual foi implementado pela toolbox do MATLAB R2016a. Dois parâmetros são importantes nesse algoritmo com relação ao desempenho da rede: a taxa de aprendizagem  $lr$  (*Learning Rate*) e a constante de momentum  $mc$  (*Momentum Constant*). Um

valor pequeno para o parâmetro  $lr$  pode fazer com que a rede demore muito para convergir, já um valor muito alto pode levar a instabilidades no treinamento. O parâmetro  $mc$  busca acelerar o processo de treinamento e evitar mínimos locais (Braga et al., 2007). Neste trabalho utilizou-se os valores 0,001, 0,006, 0,01 e 0,03 para o parâmetro  $lr$ , e foram utilizado os valores 0,01, 0,06, 0,1 e 0,3 com relação ao parâmetro  $mc$ .

## 4. RESULTADOS

### 4.1 Escolha dos Parâmetros

Esta etapa tem como objetivo selecionar os parâmetros que resultaram no melhor desempenho da rede neural, os quais são mostrados na Tabela 3.

Tabela 3: Parâmetros que serão escolhidos para a rede neural.

Parâmetro	Nível			
<b>Dimensão das subimagens</b>	10 × 10	15 × 15	20 × 20	—
<b>Taxa de treinamento</b>	60/20/20	70/15/15	80/10/10	90/5/5
<b>Taxa de aprendizagem (<i>lr</i>)</b>	0,001	0,006	0,01	0,03
<b>Constante de momentum (<i>mc</i>)</b>	0,01	0,06	0,1	0,3

Para que a escolha dos melhores parâmetros fosse feita, utilizou-se cinco medidas estatísticas: acurácia, sensibilidade, especificidade, precisão e  $F_1$ score, onde são apresentadas nas Equações 26, 27, 28, 29 e 30, respectivamente. O procedimento consistiu em realizar 4 treinamentos para cada métrica, e em seguida calcular a média e o desvio padrão. Os dados de entrada para esse procedimento são todas as 4 imagens sísmicas, pois o objetivo é avaliar o desempenho da rede para cada parâmetro.

Os resultados obtidos por esse procedimento são mostrados nas tabelas abaixo, onde a cor azul indica os melhores resultados da rede neural e a cor vermelha se refere aos piores. Além disso, Acur, Espe, Sens, Prec e  $F_1$ sc são abreviações de acurácia, especificidade, sensibilidade, precisão e  $F_1$ score, respectivamente.

Primeiramente, foram realizados os testes para a dimensão 10 × 10, onde foram obtidos resultados com até 91% de acurácia e 87% de  $F_1$ score.

Tabela 4: Resultados da rede para subimagens  $10 \times 10$  com 60% para treino, 20% para validação e 20% para teste.

Taxa de Treinamento 60/20/20											
Coeficientes		Média					Desvio Padrão				
<i>lr</i>	<i>mc</i>	Acur	Espe	Sens	Prec	F <sub>1sc</sub>	Acur	Espe	Sens	Prec	F <sub>1sc</sub>
0,001	0,01	<b>0,81</b>	0,83	0,76	0,64	<b>0,69</b>	0,01	0,01	0,01	0,03	0,02
0,001	0,06	<b>0,77</b>	0,79	0,69	0,50	<b>0,56</b>	0,06	0,06	0,09	0,22	0,22
0,001	0,1	<b>0,81</b>	0,84	0,76	0,65	<b>0,70</b>	0,00	0,00	0,00	0,01	0,01
0,001	0,3	<b>0,81</b>	0,83	0,76	0,63	<b>0,69</b>	0,01	0,01	0,02	0,02	0,01
0,006	0,01	0,85	0,87	0,81	0,72	0,76	0,01	0,01	0,01	0,02	0,01
0,006	0,06	0,85	0,87	0,79	0,74	0,76	0,00	0,01	0,01	0,02	0,00
0,006	0,1	0,85	0,87	0,80	0,73	0,77	0,01	0,01	0,01	0,02	0,01
0,006	0,3	0,85	0,87	0,80	0,73	0,77	0,00	0,01	0,01	0,02	0,01
0,01	0,01	0,87	0,88	0,83	0,76	0,79	0,00	0,01	0,01	0,01	0,01
0,01	0,06	0,87	0,88	0,83	0,75	0,79	0,00	0,00	0,01	0,01	0,00
0,01	0,1	0,87	0,89	0,82	0,77	0,80	0,00	0,00	0,01	0,00	0,00
0,01	0,3	0,86	0,88	0,82	0,75	0,78	0,00	0,01	0,01	0,01	0,01
0,03	0,01	<b>0,90</b>	0,91	0,86	0,82	<b>0,84</b>	0,01	0,01	0,01	0,01	0,01
0,03	0,06	<b>0,89</b>	0,91	0,85	0,81	<b>0,83</b>	0,01	0,01	0,02	0,01	0,01
0,03	0,1	<b>0,89</b>	0,91	0,87	0,81	<b>0,84</b>	0,01	0,01	0,01	0,03	0,02
0,03	0,3	<b>0,90</b>	0,91	0,88	0,82	<b>0,85</b>	0,01	0,01	0,01	0,01	0,01

Tabela 5: Resultados da rede para subimagens  $10 \times 10$  com 70% para treino, 15% para validação e 15% para teste.

Taxa de Treinamento 70/15/15											
Coeficientes		Média					Desvio Padrão				
<i>lr</i>	<i>mc</i>	Acur	Espe	Sens	Prec	F <sub>1sc</sub>	Acur	Espe	Sens	Prec	F <sub>1sc</sub>
0,001	0,01	<b>0,81</b>	0,83	0,75	0,65	<b>0,70</b>	0,01	0,01	0,01	0,02	0,01
0,001	0,06	<b>0,81</b>	0,83	0,77	0,62	<b>0,69</b>	0,01	0,01	0,02	0,02	0,02
0,001	0,1	<b>0,80</b>	0,82	0,73	0,61	<b>0,66</b>	0,03	0,03	0,03	0,08	0,06
0,001	0,3	<b>0,81</b>	0,83	0,75	0,65	<b>0,69</b>	0,01	0,01	0,02	0,02	0,01
0,006	0,01	0,85	0,87	0,80	0,73	0,76	0,01	0,00	0,01	0,01	0,01
0,006	0,06	0,85	0,87	0,81	0,72	0,76	0,01	0,00	0,01	0,01	0,01

0,006	0,1	0,85	0,87	0,81	0,73	0,77	0,01	0,01	0,01	0,02	0,01
0,006	0,3	0,85	0,87	0,80	0,74	0,77	0,01	0,01	0,01	0,01	0,01
0,01	0,01	0,86	0,87	0,82	0,73	0,78	0,01	0,01	0,02	0,02	0,02
0,01	0,06	0,87	0,88	0,84	0,76	0,79	0,00	0,01	0,01	0,01	0,01
0,01	0,1	0,87	0,89	0,83	0,76	0,80	0,01	0,01	0,01	0,02	0,02
0,01	0,3	0,87	0,88	0,84	0,76	0,79	0,00	0,00	0,01	0,01	0,01
0,03	0,01	0,90	0,91	0,86	0,83	0,84	0,01	0,01	0,02	0,02	0,01
0,03	0,06	0,90	0,91	0,88	0,82	0,85	0,01	0,01	0,01	0,02	0,01
0,03	0,1	0,91	0,92	0,88	0,83	0,86	0,01	0,00	0,01	0,01	0,01
0,03	0,3	0,90	0,92	0,88	0,83	0,85	0,00	0,00	0,01	0,01	0,01

Tabela 6: Resultados da rede para subimagens  $10 \times 10$  com 80% para treino, 10% para validação e 10% para teste.

Taxa de Treinamento 80/10/10											
Coeficientes		Média					Desvio Padrão				
<i>lr</i>	<i>mc</i>	Acur	Espe	Sens	Prec	$F_1sc$	Acur	Espe	Sens	Prec	$F_1sc$
0,001	0,01	0,81	0,83	0,75	0,63	0,69	0,01	0,01	0,02	0,02	0,02
0,001	0,06	0,81	0,84	0,76	0,65	0,70	0,00	0,00	0,01	0,01	0,00
0,001	0,1	0,81	0,83	0,76	0,64	0,69	0,01	0,01	0,00	0,02	0,01
0,001	0,3	0,82	0,84	0,76	0,66	0,71	0,01	0,01	0,01	0,01	0,01
0,006	0,01	0,85	0,87	0,80	0,74	0,77	0,00	0,00	0,01	0,01	0,01
0,006	0,06	0,86	0,87	0,82	0,73	0,77	0,00	0,00	0,01	0,01	0,01
0,006	0,1	0,86	0,87	0,82	0,73	0,77	0,01	0,01	0,01	0,01	0,01
0,006	0,3	0,86	0,88	0,82	0,74	0,78	0,00	0,00	0,01	0,01	0,01
0,01	0,01	0,87	0,89	0,84	0,77	0,80	0,00	0,00	0,00	0,01	0,00
0,01	0,06	0,87	0,88	0,83	0,76	0,79	0,01	0,01	0,01	0,02	0,01
0,01	0,1	0,87	0,89	0,83	0,77	0,80	0,00	0,00	0,01	0,00	0,01
0,01	0,3	0,87	0,89	0,84	0,76	0,80	0,01	0,00	0,02	0,00	0,01
0,03	0,01	0,91	0,92	0,90	0,83	0,87	0,01	0,00	0,01	0,01	0,01
0,03	0,06	0,89	0,91	0,87	0,80	0,83	0,02	0,02	0,03	0,03	0,03
0,03	0,1	0,91	0,92	0,89	0,84	0,86	0,00	0,00	0,01	0,01	0,01
0,03	0,3	0,90	0,91	0,89	0,82	0,85	0,01	0,01	0,02	0,02	0,01

Tabela 7: Resultados da rede para subimagens  $10 \times 10$  com 90% para treino, 5% para validação e 5% para teste.

Taxa de Treinamento 90/5/5											
Coeficientes		Média					Desvio Padrão				
<i>lr</i>	<i>mc</i>	Acur	Espe	Sens	Prec	F <sub>1</sub> sc	Acur	Espe	Sens	Prec	F <sub>1</sub> sc
0,001	0,01	<b>0,77</b>	0,82	0,69	0,62	<b>0,65</b>	0,06	0,03	0,11	0,04	0,07
0,001	0,06	<b>0,81</b>	0,83	0,76	0,64	0,69	0,01	0,00	0,02	0,01	0,01
0,001	0,1	<b>0,81</b>	0,83	0,75	0,62	<b>0,68</b>	0,01	0,01	0,01	0,04	0,02
0,001	0,3	<b>0,81</b>	0,83	0,75	0,64	0,69	0,00	0,00	0,01	0,02	0,00
0,006	0,01	0,85	0,87	0,80	0,73	0,76	0,00	0,01	0,00	0,01	0,01
0,006	0,06	0,84	0,86	0,79	0,70	0,74	0,02	0,02	0,03	0,04	0,03
0,006	0,1	0,84	0,86	0,80	0,71	0,75	0,01	0,02	0,02	0,04	0,03
0,006	0,3	0,86	0,88	0,81	0,75	0,78	0,00	0,00	0,01	0,01	0,01
0,01	0,01	0,87	0,88	0,83	0,76	0,79	0,01	0,00	0,01	0,01	0,01
0,01	0,06	0,87	0,89	0,83	0,76	0,79	0,01	0,01	0,01	0,03	0,02
0,01	0,1	<b>0,81</b>	0,84	0,72	0,65	<b>0,68</b>	0,12	0,10	0,22	0,23	0,23
0,01	0,3	0,88	0,89	0,84	0,77	0,81	0,00	0,01	0,01	0,01	0,01
0,03	0,01	<b>0,91</b>	0,92	0,90	0,84	<b>0,87</b>	0,01	0,00	0,01	0,01	0,01
0,03	0,06	<b>0,80</b>	0,82	0,72	0,55	<b>0,58</b>	0,09	0,09	0,15	0,31	0,31
0,03	0,1	0,85	0,86	0,79	0,64	<b>0,66</b>	0,11	0,11	0,18	0,36	0,36
0,03	0,3	<b>0,90</b>	0,91	0,88	0,82	<b>0,85</b>	0,02	0,02	0,03	0,04	0,04

Logo em seguida, foi realizado o procedimento para a dimensão  $15 \times 15$ , onde foram obtidos resultados com até 94% de acurácia e 94% de F<sub>1</sub>score.

Tabela 8: Resultados da rede para subimagens  $15 \times 15$  com 60% para treino, 20% para validação e 20% para teste.

Taxa de Treinamento 60/20/20											
Coeficientes		Média					Desvio Padrão				
<i>lr</i>	<i>mc</i>	Acur	Espe	Sens	Prec	F <sub>1</sub> sc	Acur	Espe	Sens	Prec	F <sub>1</sub> sc
0,001	0,01	0,87	0,89	0,83	0,77	0,80	0,01	0,01	0,01	0,02	0,01
0,001	0,06	0,87	0,88	0,84	0,75	0,80	0,01	0,02	0,00	0,04	0,02
0,001	0,1	<b>0,86</b>	0,89	0,81	0,77	<b>0,79</b>	0,01	0,01	0,02	0,01	0,02

0,001	0,3	<b>0,83</b>	0,86	0,77	0,70	<b>0,73</b>	0,08	0,06	0,13	0,13	0,13
0,006	0,01	0,91	0,92	0,87	0,84	0,86	0,01	0,01	0,02	0,03	0,02
0,006	0,06	0,90	0,92	0,88	0,83	0,85	0,01	0,01	0,01	0,02	0,01
0,006	0,1	<b>0,92</b>	0,94	0,88	0,87	<b>0,88</b>	0,01	0,01	0,01	0,02	0,01
0,006	0,3	<b>0,92</b>	0,93	0,88	0,86	<b>0,87</b>	0,01	0,00	0,02	0,00	0,01
0,01	0,01	<b>0,92</b>	0,94	0,88	0,87	<b>0,87</b>	0,01	0,00	0,03	0,00	0,02
0,01	0,06	0,91	0,93	0,88	0,85	0,87	0,02	0,02	0,03	0,04	0,03
0,01	0,1	<b>0,92</b>	0,93	0,90	0,85	<b>0,88</b>	0,02	0,01	0,03	0,03	0,03
0,01	0,3	<b>0,92</b>	0,94	0,89	0,87	<b>0,88</b>	0,01	0,01	0,01	0,02	0,01
0,03	0,01	<b>0,92</b>	0,92	0,90	0,84	<b>0,87</b>	0,01	0,01	0,01	0,02	0,01
0,03	0,06	<b>0,92</b>	0,94	0,90	0,87	<b>0,88</b>	0,01	0,01	0,01	0,01	0,01
0,03	0,1	0,90	0,92	0,86	0,84	0,85	0,03	0,02	0,05	0,04	0,04
0,03	0,3	<b>0,92</b>	0,94	0,89	0,88	<b>0,89</b>	0,01	0,01	0,03	0,02	0,01

Tabela 9: Resultados da rede para subimagens  $15 \times 15$  com 70% para treino, 15% para validação e 15% para teste.

Taxa de Treinamento 70/15/15											
Coeficientes		Média					Desvio Padrão				
<i>lr</i>	<i>mc</i>	Acur	Espe	Sens	Prec	F <sub>1sc</sub>	Acur	Espe	Sens	Prec	F <sub>1sc</sub>
0,001	0,01	0,88	0,89	0,85	0,77	0,80	0,01	0,01	0,02	0,03	0,02
0,001	0,06	<b>0,87</b>	0,89	0,83	0,77	<b>0,80</b>	0,00	0,01	0,01	0,02	0,01
0,001	0,1	<b>0,87</b>	0,88	0,83	0,76	<b>0,79</b>	0,01	0,01	0,01	0,02	0,01
0,001	0,3	<b>0,87</b>	0,89	0,84	0,76	<b>0,80</b>	0,01	0,01	0,01	0,02	0,01
0,006	0,01	0,92	0,93	0,89	0,87	0,88	0,00	0,00	0,01	0,01	0,01
0,006	0,06	0,92	0,94	0,89	0,88	0,88	0,01	0,00	0,02	0,01	0,01
0,006	0,1	0,92	0,93	0,90	0,86	0,88	0,01	0,01	0,01	0,02	0,01
0,006	0,3	0,91	0,92	0,88	0,84	0,86	0,02	0,02	0,03	0,04	0,03
0,01	0,01	0,91	0,92	0,88	0,84	0,86	0,02	0,02	0,02	0,06	0,04
0,01	0,06	0,91	0,93	0,89	0,85	0,87	0,01	0,02	0,01	0,04	0,02
0,01	0,1	<b>0,94</b>	0,94	0,92	0,88	<b>0,90</b>	0,01	0,01	0,01	0,01	0,01
0,01	0,3	<b>0,85</b>	0,86	0,80	0,66	<b>0,69</b>	0,10	0,10	0,14	0,32	0,29
0,03	0,01	<b>0,93</b>	0,94	0,90	0,87	<b>0,89</b>	0,01	0,01	0,02	0,03	0,02



0,03	0,06	0,92	0,93	0,88	0,87	0,88	0,01	0,01	0,02	0,02	0,02
0,03	0,1	<b>0,93</b>	0,94	0,89	0,88	<b>0,89</b>	0,02	0,01	0,02	0,03	0,02
0,03	0,3	0,91	0,92	0,90	0,84	0,87	0,03	0,02	0,04	0,04	0,04

Tabela 10: Resultados da rede para subimagens  $15 \times 15$  com 80% para treino, 10% para validação e 10% para teste.

Taxa de Treinamento 80/10/10											
Coeficientes		Média					Desvio Padrão				
<i>lr</i>	<i>mc</i>	Acur	Espe	Sens	Prec	$F_1sc$	Acur	Espe	Sens	Prec	$F_1sc$
0,001	0,01	0,88	0,89	0,84	0,78	0,81	0,01	0,01	0,03	0,03	0,02
0,001	0,06	0,88	0,90	0,85	0,78	0,81	0,01	0,00	0,01	0,01	0,01
0,001	0,1	0,87	0,88	0,83	0,75	0,79	0,01	0,01	0,02	0,02	0,02
0,001	0,3	0,87	0,89	0,83	0,76	0,79	0,01	0,01	0,01	0,02	0,01
0,006	0,01	0,92	0,94	0,90	0,87	0,88	0,01	0,01	0,02	0,01	0,01
0,006	0,06	0,92	0,94	0,90	0,87	0,88	0,01	0,01	0,02	0,02	0,02
0,006	0,1	0,92	0,93	0,89	0,85	0,87	0,02	0,02	0,04	0,04	0,04
0,006	0,3	0,93	0,93	0,91	0,87	0,89	0,01	0,00	0,01	0,01	0,01
0,01	0,01	<b>0,86</b>	0,88	0,78	0,70	<b>0,73</b>	0,13	0,11	0,22	0,31	0,28
0,01	0,06	0,93	0,94	0,91	0,89	0,90	0,01	0,01	0,02	0,01	0,01
0,01	0,1	<b>0,94</b>	0,95	0,92	0,90	<b>0,91</b>	0,01	0,01	0,01	0,01	0,01
0,01	0,3	<b>0,85</b>	0,89	0,79	0,80	<b>0,79</b>	0,13	0,08	0,19	0,14	0,16
0,03	0,01	<b>0,94</b>	0,98	0,90	0,98	<b>0,94</b>	0,02	0,01	0,03	0,02	0,02
0,03	0,06	0,93	0,97	0,90	0,98	0,94	0,02	0,02	0,02	0,03	0,03
0,03	0,1	0,93	0,97	0,90	0,98	0,94	0,02	0,02	0,02	0,04	0,03
0,03	0,3	<b>0,94</b>	0,97	0,91	0,98	<b>0,94</b>	0,01	0,01	0,02	0,02	0,02

Tabela 11: Resultados da rede para subimagens  $15 \times 15$  com 90% para treino, 5% para validação e 5% para teste.

Taxa de Treinamento 90/5/5											
Coeficientes		Média					Desvio Padrão				
<i>lr</i>	<i>mc</i>	Acur	Espe	Sens	Prec	$F_1sc$	Acur	Espe	Sens	Prec	$F_1sc$
0,001	0,01	<b>0,76</b>	0,81	0,65	0,60	<b>0,61</b>	0,12	0,09	0,20	0,24	0,22
0,001	0,06	<b>0,79</b>	0,83	0,70	0,66	<b>0,68</b>	0,14	0,11	0,23	0,22	0,23

0,001	0,1	0,87	0,89	0,84	0,76	0,80	0,01	0,01	0,02	0,02	0,01
0,001	0,3	0,88	0,89	0,84	0,77	0,81	0,01	0,01	0,01	0,02	0,01
0,006	0,01	<b>0,85</b>	0,87	0,80	0,72	0,76	0,11	0,09	0,18	0,21	0,20
0,006	0,06	0,86	0,87	0,73	0,65	<b>0,66</b>	0,11	0,12	0,28	0,38	0,38
0,006	0,1	0,93	0,94	0,91	0,88	0,89	0,01	0,00	0,02	0,00	0,01
0,006	0,3	0,91	0,92	0,88	0,84	0,86	0,03	0,02	0,03	0,05	0,04
0,01	0,01	0,92	0,93	0,89	0,86	0,87	0,02	0,02	0,03	0,04	0,04
0,01	0,06	0,93	0,94	0,92	0,88	0,90	0,03	0,02	0,04	0,05	0,04
0,01	0,1	<b>0,94</b>	0,95	0,92	0,90	<b>0,91</b>	0,01	0,01	0,01	0,02	0,01
0,01	0,3	<b>0,94</b>	0,95	0,93	0,90	<b>0,91</b>	0,01	0,01	0,02	0,01	0,01
0,03	0,01	<b>0,94</b>	0,97	0,91	0,97	<b>0,94</b>	0,03	0,02	0,05	0,05	0,05
0,03	0,06	0,93	0,97	0,90	0,97	0,94	0,03	0,02	0,03	0,05	0,04
0,03	0,1	0,93	0,94	0,90	0,88	0,89	0,04	0,03	0,06	0,07	0,06
0,03	0,3	<b>0,94</b>	0,98	0,91	0,98	<b>0,94</b>	0,03	0,03	0,03	0,06	0,04

Finalmente, os testes foram para a dimensão  $20 \times 20$ , onde os resultados obtidos foram de até 98% de acurácia e 98% de  $F_1$  score.

Tabela 12: Resultados da rede para subimagens  $20 \times 20$  com 60% para treino, 20% para validação e 20% para teste.

Taxa de Treinamento 60/20/20											
Coeficientes		Média					Desvio Padrão				
<i>lr</i>	<i>mc</i>	Acur	Espe	Sens	Prec	$F_1$ sc	Acur	Espe	Sens	Prec	$F_1$ sc
0,001	0,01	<b>0,86</b>	0,89	0,80	0,77	<b>0,78</b>	0,01	0,01	0,05	0,03	0,01
0,001	0,06	0,87	0,89	0,81	0,77	0,79	0,01	0,01	0,01	0,03	0,02
0,001	0,1	0,87	0,89	0,82	0,77	0,80	0,01	0,01	0,01	0,03	0,02
0,001	0,3	<b>0,86</b>	0,88	0,82	0,76	<b>0,79</b>	0,01	0,00	0,02	0,01	0,01
0,006	0,01	0,89	0,90	0,85	0,80	0,82	0,02	0,01	0,05	0,03	0,03
0,006	0,06	0,90	0,92	0,86	0,84	0,85	0,03	0,02	0,06	0,03	0,05
0,006	0,1	0,89	0,90	0,87	0,80	0,83	0,02	0,02	0,02	0,05	0,03
0,006	0,3	0,89	0,91	0,84	0,82	0,83	0,02	0,03	0,02	0,07	0,04
0,01	0,01	0,90	0,93	0,86	0,85	0,85	0,02	0,01	0,02	0,03	0,02

0,01	0,06	<b>0,91</b>	0,93	0,88	0,86	<b>0,87</b>	0,01	0,01	0,02	0,01	0,01
0,01	0,1	0,89	0,91	0,85	0,81	0,83	0,04	0,03	0,04	0,07	0,06
0,01	0,3	0,89	0,91	0,84	0,82	0,83	0,01	0,01	0,03	0,02	0,02
0,03	0,01	0,90	0,91	0,86	0,82	0,84	0,00	0,01	0,01	0,02	0,00
0,03	0,06	<b>0,91</b>	0,92	0,88	0,84	<b>0,86</b>	0,02	0,01	0,04	0,02	0,02
0,03	0,1	<b>0,91</b>	0,93	0,86	0,86	<b>0,86</b>	0,01	0,01	0,02	0,02	0,02
0,03	0,3	0,89	0,90	0,85	0,80	0,83	0,03	0,02	0,04	0,05	0,04

Tabela 13: Resultados da rede para subimagens  $20 \times 20$  com 70% para treino, 15% para validação e 15% para teste.

Taxa de Treinamento 70/15/15											
Coeficientes		Média					Desvio Padrão				
<i>lr</i>	<i>mc</i>	Acur	Espe	Sens	Prec	F <sub>1</sub> sc	Acur	Espe	Sens	Prec	F <sub>1</sub> sc
0,001	0,01	<b>0,86</b>	0,88	0,82	0,76	<b>0,79</b>	0,01	0,01	0,01	0,03	0,01
0,001	0,06	0,88	0,89	0,84	0,77	0,81	0,01	0,01	0,01	0,03	0,02
0,001	0,1	<b>0,87</b>	0,89	0,82	0,77	<b>0,79</b>	0,01	0,01	0,02	0,02	0,02
0,001	0,3	<b>0,86</b>	0,88	0,80	0,76	<b>0,78</b>	0,01	0,01	0,03	0,01	0,02
0,006	0,01	0,91	0,92	0,87	0,84	0,85	0,03	0,03	0,03	0,06	0,04
0,006	0,06	0,91	0,92	0,90	0,83	0,86	0,01	0,00	0,03	0,01	0,01
0,006	0,1	0,91	0,92	0,88	0,84	0,86	0,03	0,02	0,05	0,04	0,05
0,006	0,3	<b>0,93</b>	0,95	0,90	0,90	<b>0,90</b>	0,01	0,01	0,03	0,02	0,01
0,01	0,01	0,90	0,92	0,87	0,83	0,85	0,03	0,03	0,04	0,07	0,05
0,01	0,06	<b>0,93</b>	0,94	0,90	0,88	<b>0,89</b>	0,02	0,02	0,04	0,04	0,03
0,01	0,1	<b>0,93</b>	0,95	0,89	0,91	<b>0,90</b>	0,02	0,02	0,02	0,04	0,03
0,01	0,3	0,92	0,94	0,88	0,87	0,87	0,02	0,02	0,02	0,04	0,03
0,03	0,01	<b>0,93</b>	0,94	0,90	0,87	<b>0,89</b>	0,01	0,02	0,02	0,03	0,02
0,03	0,06	0,91	0,93	0,87	0,85	0,86	0,03	0,02	0,04	0,04	0,04
0,03	0,1	<b>0,93</b>	0,94	0,89	0,88	<b>0,89</b>	0,02	0,02	0,03	0,05	0,04
0,03	0,3	0,91	0,93	0,86	0,86	0,86	0,02	0,02	0,03	0,04	0,04

Tabela 14: Resultados da rede para subimagens  $20 \times 20$  com 80% para treino, 10% para validação e 10% para teste.

Taxa de Treinamento 80/10/10											
Coeficientes		Média					Desvio Padrão				
<i>lr</i>	<i>mc</i>	Acur	Espe	Sens	Prec	F <sub>1sc</sub>	Acur	Espe	Sens	Prec	F <sub>1sc</sub>
0,001	0,01	0,86	0,88	0,82	0,76	0,79	0,02	0,02	0,03	0,03	0,02
0,001	0,06	0,86	0,87	0,81	0,74	0,77	0,03	0,03	0,04	0,06	0,05
0,001	0,1	<b>0,81</b>	0,85	0,72	0,68	<b>0,70</b>	0,13	0,10	0,22	0,23	0,23
0,001	0,3	0,87	0,89	0,83	0,78	0,80	0,02	0,01	0,05	0,02	0,03
0,006	0,01	0,91	0,92	0,88	0,83	0,85	0,02	0,02	0,04	0,04	0,04
0,006	0,06	0,93	0,94	0,91	0,87	0,89	0,03	0,03	0,04	0,06	0,05
0,006	0,1	<b>0,80</b>	0,81	0,75	0,48	<b>0,53</b>	0,12	0,12	0,18	0,37	0,35
0,006	0,3	0,93	0,94	0,92	0,87	0,89	0,01	0,00	0,02	0,01	0,01
0,01	0,01	0,92	0,93	0,89	0,85	0,87	0,01	0,02	0,02	0,04	0,02
0,01	0,06	0,91	0,92	0,88	0,83	0,86	0,05	0,05	0,07	0,10	0,08
0,01	0,1	0,93	0,94	0,91	0,89	0,90	0,01	0,01	0,01	0,02	0,01
0,01	0,3	0,94	0,94	0,92	0,89	0,90	0,02	0,02	0,03	0,04	0,03
0,03	0,01	<b>0,98</b>	1,00	0,96	1,00	<b>0,98</b>	0,02	0,02	0,03	0,04	0,03
0,03	0,06	0,97	0,99	0,96	0,99	0,97	0,06	0,05	0,07	0,11	0,09
0,03	0,1	0,97	0,98	0,96	0,98	0,88	0,02	0,02	0,04	0,04	0,03
0,03	0,3	<b>0,98</b>	1,00	0,96	1,00	<b>0,98</b>	0,03	0,02	0,04	0,04	0,04

Tabela 15: Resultados da rede para subimagens  $20 \times 20$  com 90% para treino, 5% para validação e 5% para teste.

Taxa de Treinamento 90/5/5											
Coeficientes		Média					Desvio Padrão				
<i>lr</i>	<i>mc</i>	Acur	Espe	Sens	Prec	F <sub>1sc</sub>	Acur	Espe	Sens	Prec	F <sub>1sc</sub>
0,001	0,01	0,88	0,89	0,85	0,77	0,81	0,01	0,01	0,01	0,01	0,01
0,001	0,06	0,87	0,89	0,84	0,77	0,80	0,02	0,02	0,02	0,04	0,03
0,001	0,1	0,88	0,89	0,84	0,78	0,81	0,01	0,01	0,01	0,02	0,01
0,001	0,3	0,85	0,87	0,80	0,73	0,76	0,04	0,04	0,03	0,11	0,07
0,006	0,01	<b>0,94</b>	0,95	0,93	0,90	<b>0,91</b>	0,03	0,02	0,03	0,05	0,04
0,006	0,06	<b>0,82</b>	0,84	0,74	0,65	<b>0,69</b>	0,16	0,13	0,24	0,29	0,27

0,006	0,1	0,89	0,90	0,85	0,79	0,82	0,08	0,07	0,13	0,15	0,14
0,006	0,3	0,84	0,88	0,77	0,78	0,77	0,14	0,09	0,21	0,16	0,19
0,01	0,01	0,89	0,91	0,85	0,82	0,84	0,05	0,04	0,08	0,07	0,08
0,01	0,06	<b>0,79</b>	0,81	0,66	0,53	<b>0,56</b>	0,09	0,09	0,21	0,31	0,31
0,01	0,1	<b>0,91</b>	0,92	0,88	0,83	<b>0,86</b>	0,06	0,05	0,08	0,12	0,10
0,01	0,3	0,86	0,87	0,82	0,67	0,71	0,11	0,11	0,15	0,32	0,29
0,03	0,01	<b>0,81</b>	0,84	0,69	0,60	<b>0,63</b>	0,12	0,11	0,26	0,33	0,32
0,03	0,06	<b>0,91</b>	0,92	0,88	0,83	<b>0,86</b>	0,05	0,04	0,07	0,09	0,08
0,03	0,1	0,83	0,86	0,75	0,68	0,71	0,15	0,13	0,23	0,30	0,27
0,03	0,3	<b>0,77</b>	0,82	0,68	0,65	<b>0,66</b>	0,12	0,07	0,18	0,11	0,14

É possível notar que os melhores valores foram das dimensões  $15 \times 15$  e  $20 \times 20$ . Além disso, as taxas de treinamento 80/10/10 e 90/5/5 também obtiveram os melhores resultados. Com relação a taxa de aprendizagem ( $lr$ ) o melhor valor foi 0,03, já a constante de momentum ( $mc$ ) ficou entre 0,01 e 0,3. Sendo assim, fez-se necessário realizar outro teste para definir qual os melhores parâmetros para a rede. Nesse segundo teste, também foram utilizadas as 4 imagens sísmicas como entrada para rede neural.

Primeiramente foram feitos os testes para a dimensão  $15 \times 15$ , onde obteve-se até 94,9% de acurácia e 95,1% de  $F_1$  score (Tabela 16).

Tabela 16: Segundo teste para subimagens  $15 \times 15$  com 80% para treino, 10% para validação e 10% para teste e  $lr = 0,03$ .

Taxa de Treinamento 80/10/10										
$lr = 0,03$										
Coeficiente	Média					Desvio Padrão				
$mc$	Acur	Espe	Sens	Prec	$F_1$ sc	Acur	Espe	Sens	Prec	$F_1$ sc
0,01	0,949	0,986	0,917	0,987	0,950	0,002	0,002	0,002	0,002	0,002
0,3	<b>0,949</b>	0,985	0,918	0,986	<b>0,951</b>	0,003	0,004	0,003	0,003	0,003

Tabela 17: Segundo teste para subimagens  $15 \times 15$  com 90% para treino, 5% para validação e 5% para teste e  $lr = 0,03$ .

Taxa de Treinamento 90/5/5										
$lr = 0,03$										
Coeficiente	Média					Desvio Padrão				
$mc$	Acur	Espe	Sens	Prec	$F_1sc$	Acur	Espe	Sens	Prec	$F_1sc$
0,01	<b>0,948</b>	0,988	0,914	0,989	<b>0,950</b>	0,004	0,003	0,004	0,003	0,003
0,3	0,945	0,985	0,911	0,987	0,947	0,003	0,003	0,004	0,003	0,003

Logo em seguida, foram feitos os testes para a dimensão  $20 \times 20$ , onde foram obtidos até 98,3% para acurácia e  $F_1$ score, além de 100% para especificidade e precisão (Tabela 18).

Tabela 18: Segundo teste para subimagens  $20 \times 20$  com 80% para treino, 10% para validação e 10% para teste e  $lr = 0,03$ .

Taxa de Treinamento 80/10/10										
$lr = 0,03$										
Coeficiente	Média					Desvio Padrão				
$mc$	Acur	Espe	Sens	Prec	$F_1sc$	Acur	Espe	Sens	Prec	$F_1sc$
0,01	<b>0,983</b>	1,000	0,967	1,000	<b>0,983</b>	0,002	0,000	0,004	0,000	0,002
0,3	0,981	1,000	0,965	1,000	0,982	0,001	0,000	0,002	0,000	0,001

Tabela 19: Segundo teste para subimagens  $20 \times 20$  com 90% para treino, 5% para validação e 5% para teste e  $lr = 0,03$ .

Taxa de Treinamento 90/5/5										
$lr = 0,03$										
Coeficiente	Média					Desvio Padrão				
$mc$	Acur	Espe	Sens	Prec	$F_1sc$	Acur	Espe	Sens	Prec	$F_1sc$
0,01	0,981	0,999	0,965	0,999	0,982	0,000	0,000	0,001	0,000	0,000
0,3	<b>0,982</b>	0,997	0,968	0,997	<b>0,982</b>	0,002	0,001	0,004	0,001	0,002

A dimensão  $20 \times 20$  obteve melhores resultados do que a dimensão  $15 \times 15$ . Já a taxa de treinamento 80/10/10 obteve resultados levemente melhores que a taxa 90/5/5. O  $mc$  escolhido foi o 0,01, pois ele retornou o melhor valor com a taxa escolhida 80/10/10.

Portanto, os melhores parâmetros para a rede neural são:

- Dimensão das subimagens:  $20 \times 20$ ;
- Taxa de treinamento: 80/10/10;
- Taxa de aprendizagem ( $lr$ ): 0,03;
- Constante de momentum ( $mc$ ): 0,01.

## 4.2 Identificação das Regiões de Interesse


Nesta seção são apresentadas as respostas da rede neural, cujo objetivo é que a mesma identifique as regiões com maior possibilidade de concentração de hidrocarbonetos (regiões de interesse). Para que o desempenho da rede seja o melhor possível, foram utilizados os parâmetros escolhidos na seção 4.1.

O procedimento para tal classificação consiste em que a rede receba as imagens sísmicas como entrada, em seguida passe pelo seu processo de aprendizado, e como resposta são retornadas imagens sísmicas com as regiões de interesse identificadas.

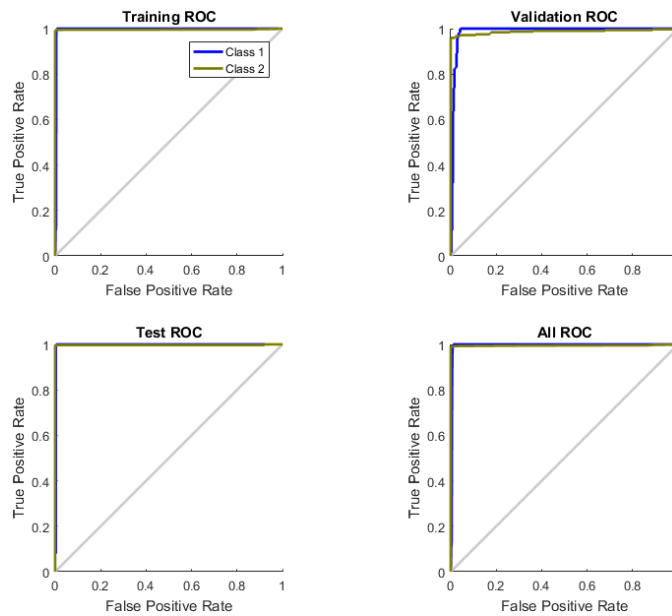
Dois casos foram abordados nesse trabalho: o primeiro caso consiste em mandar todas as quatro imagens como entrada para a rede, e em seguida selecionar uma dessas imagens para que a rede a classifique. O segundo caso consiste em selecionar três das quatro imagens como entrada para a rede neural, e em seguida utilizar a quarta imagem (a imagem que a rede nunca viu), para que a rede a classifique. Esse segundo caso foi chamado de teste às cegas.

### 4.2.1 Caso 1: Identificação da Rede Utilizando Todas as Imagens

Nesse primeiro caso são utilizadas todas as quatro imagens para o aprendizado da rede neural. Como ilustração do desempenho da rede, a Figura 26 (a) mostra a matriz de confusão para cada taxa de treinamento (treino, validação e teste), onde pode-se perceber que há ocorrências de falsos negativos, mas a rede obteve um alto índice de verdadeiros positivos e verdadeiros negativos. Na Figura 26 (b) é apresentada a curva ROC também para cada taxa de treinamento, onde nota-se que a rede neural foi um bom classificador, pois a área sob a curva está muito próxima de 1.



(a)




(b)


Figura 26: Avaliação do desempenho da rede (Caso 1). (a) Resultados para a matriz de confusão em cada taxa de treinamento, (b) Resultados da curva ROC para cada taxa de treinamento.

Logo em seguida, é escolhida uma imagem dentre as 4 imagens para que a rede identifique as regiões de interesse. A Figura 27 apresenta uma comparação entre os resultados da imagem SEAL-M-567-NW, onde na Figura 27 (a) ilustra-se o resultado esperado e na Figura 27 (b) é mostrado o resultado obtido pela rede neural. Os blocos com bordas brancas são os que estão de acordo com o especialista, já os com bordas pretas não estão.





(a)



(b)

Figura 27: Comparação entre os resultados no Caso 1. (a) Resultado esperado, (b) resultado obtido pela rede neural.

Como era esperado, houve algumas identificações em que a rede considera algumas subimagens como sendo região de interesse, diferentemente do especialista. Também é possível notar que ela obteve um alto índice de acerto com relação a classificação das regiões de interesse. Além disso, há uma aglomeração próxima a região de interesse, o que de fato auxilia o geólogo em sua tomada de decisão.

### 4.2.2 Caso 2: Teste às Cegas

Nesse segundo caso são enviados para o aprendizado da rede 3 imagens sísmicas de um total de 4. Para ilustrar o desempenho da rede, a Figura 28 (a) mostra a matriz de confusão para cada taxa de treinamento (treino, validação e teste), onde, assim como no caso 1, também há ocorrências de falsos negativos, mas também foi obtido muitas ocorrências de verdadeiros positivos e negativos. A Figura 28 (b) ilustra a curva ROC, onde a área sob a curva (em cada taxa de treinamento) é próximo de 1, o qual mostra que a rede é um bom classificador.

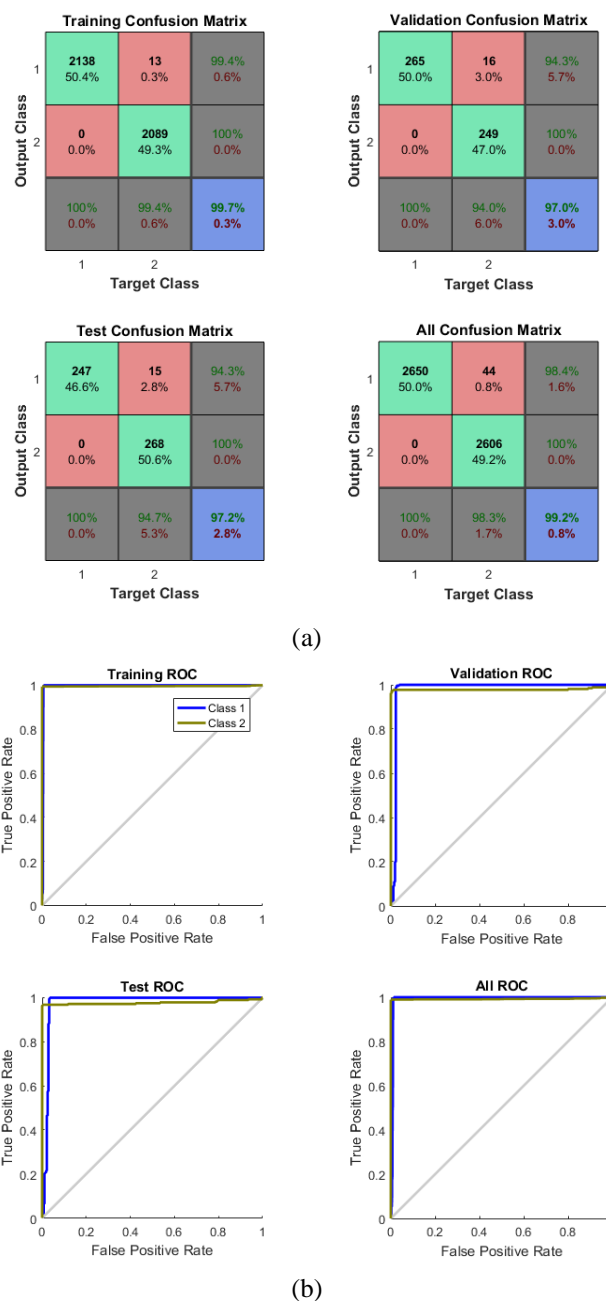




Figura 28: Avaliação do desempenho da rede (Caso 2). (a) Resultado para a matriz de confusão para cada taxa de treinamento, (b) Resultado da curva ROC em cada taxa de treinamento.

Uma imagem foi separada (SEAL-M-567-NW) para testar a rede neural, ou seja, realizar o teste às cegas, onde o resultado é mostrado na Figura 29. O resultado esperado é ilustrado na Figura 29 (a). Já as identificações das regiões de interesse pela rede neural, é mostrado na Figura 29 (b). Os blocos com bordas brancas foram de acordo com a classificação do especialista, já os com bordas pretas não.




(a)




(b)

Figura 29: Comparação entre os resultados no Caso 2 (imagem SEAL-M-567-NW). (a) Resultado esperado, (b) Resultado obtido pela rede neural.

Para ilustrar mais uma classificação da rede, a Figura 30 mostra a comparação entre os resultados com relação a imagem sísmica (SEAL-M-567-SW). A Figura 30 (a) ilustra o resultado esperado. A Figura 30 (b) apresenta o resultado obtido pela rede neural.



(a)



(b)

Figura 30: Comparação entre os resultados no Caso 2 (imagem SEAL-M-567-SW). (a) Resultado esperado, (b) resultado obtido pela rede neural.

Assim como no Caso 1, a rede também classificou algumas subimagens como regiões de interesse, onde o geólogo não considerou a mesma sendo tal região, mas nota-se também que há um aglomerado dessas classificações equivocadas próximas a região de interesse. Além disso, tanto no Caso 1 quanto no Caso 2, a rede classificou bem as regiões de não interesse, o que é muito importante tendo em vista que impede a perfuração em regiões com pouca ou nenhuma concentração de hidrocarbonetos.

## 5. CONSIDERAÇÕES FINAIS

A utilização de inteligência artificial (IA) para auxiliar geólogos e geofísicos em suas tomadas de decisões será de grande importância para as indústrias petrolíferas. Nesse sentido, o objetivo desse trabalho de utilizar redes neurais para auxiliar tais profissionais em identificar regiões com maior possibilidade de concentração de hidrocarbonetos foi alcançado.

O fato da rede classificar algumas regiões de forma equivocada no teste às cegas, não diminui sua capacidade, tendo em vista que a mesma apresentou aglomerações próximas as regiões de interesse.

Os resultados que a rede apresenta ainda podem ser melhorados, como por exemplo, obtendo um banco maior de imagens, tendo em vista que só foram usadas 4 imagens para o treinamento da rede. Também auxiliaria na melhora dos resultados imagens com melhor resolução. Além disso, adicionar outros descritores, como por exemplo as transformadas de Wavelet, poderia ser de grande ajuda para a rede neural.

Portanto, baseado nos resultados apresentados e nas possíveis melhoras, essa técnica pode vir a ser uma tendência nas indústrias petrolíferas para ajudar seus especialistas a encontrar as regiões de interesse.

## 6. REFERÊNCIAS BIBLIOGRÁFICAS

ALMEIDA, A. B. *Usando o computador para processamento de imagens médicas*. Disponível em: <<http://www.informaticamedica.org.br/informaticamedica/n0106/imagens.htm/>> Acesso em: 27 de março de 2018.

ANDRADE, L. E. C. L. *Interpretação sísmica 2D na área de Espigão, Bacia de Barreirinhas, município de Santo Amaro – MA*. Monografia – Instituto de Geociências, Universidade Federal da Bahia, Salvador, 2009.

ANP. Agência Nacional do Petróleo, Gás Natural e Biocombustíveis. Disponível em: <<http://rodadas.anp.gov.br/pt/concessao-de-blocos-exploratorios-1/13-rodada-de-licitacao-de-blocos/>> Acesso em: 05 de outubro de 2017.

BARALDI, A.; PARMIGGIANI, F. An Investigation of the Textural Characteristics Associated with Gray Level Cooccurrence Matrix Statistical Parameters. *Geoscience and Remote Sensing, IEEE Transactions on*, v. 33, n. 2, p. 293-304, 1995.

BARBOSA, D. P. *Avaliação de descritores texturais geoestatísticos e de Haralick para o reconhecimento de plantas Daninhas*. Dissertação – Programa de Pós-Graduação de Estatística Aplicada e Biometria, Universidade Federal de Viçosa, Viçosa. 2009.

BARROS, M. S. F. *Detecção de falhas geológicas em dados sísmicos usando covariograma e aprendizado de máquina*. Monografia – Curso de Ciências da Computação, Universidade Federal do Maranhão, São Luís, 2013.

BRAGA, A. P.; CARVALHO, A. C. P. L. F.; LUDERMIR T. B. *Redes neurais artificiais: teoria e aplicações*. 2nd. ed. Rio de Janeiro: LTC, 2007.

ERPEN, L. R. C. *Reconhecimento de padrões em imagens por descritores de forma*. Dissertação – Programa de Pós-Graduação em Computação, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2004.

GONZALEZ, R. C.; WOODS, R. E. *Digital Image Processing*. 3rd. ed. Addison-Wesley Publishing Company, INC., 2008.

HARALICK, R. M.; SHANMUGAM, K. Textural Features for Image Classification. *IEEE Transactions on Systems, Man, and Cybernetics*, v. SMC-3, n. 6, p. 610-621, 1973.

MARQUÊS FILHO, O.; VIEIRA NETO, H. *Processamento digital de imagens*. Rio de Janeiro: Brasport, 1999.

MOTTA, S. A. C. S. *Detecção de falhas em dados sísmicos 3D utilizando funções geoestatísticas e SVM*. Dissertação – Programa de Pós-Graduação em Engenharia de Eletricidade, Universidade Federal do Maranhão, São Luís, 2015.

NASCIMENTO, J. P. R. *Análise e classificação de imagens baseadas em características de textura utilizando matrizes de co-ocorrência*. Dissertação – Programa de Pós-Graduação em Informática, Universidade Federal do Paraná, Curitiba, 2003.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. *Redes neurais artificiais para engenharia e ciências aplicadas: curso prático*. São Paulo: Artliber, 2010.

SOUSA JÚNIOR, O. S. *Método de reconhecimento pessoal através da íris usando funções geoestatísticas*. Dissertação – Programa de Pós-Graduação em Engenharia de Eletricidade, Universidade Federal do Maranhão, São Luís, 2006.